



Universitat Ramon Llull

TESIS DOCTORAL

Título TÉCNICAS DE SISTEMAS AUTOMATICOS DE SOPORTE
VECTORIAL EN LA RÉPLICA DEL RATING CREDITICIO

Realizada por RICARDO ALEX CAMPOS ESPINOZA

en el Centro ESADE

Departamento MARKETING, OPERACIONES Y FINANZAS

Dirigida por DRA. XARI ROVIRA LLOBERA
DRA. CARMEN ANSOTEGUI OLCOZ

TÉCNICAS DE SISTEMAS AUTOMÁTICOS DE SOPORTE VECTORIAL EN LA RÉPLICA DEL RATING CREDITICIO

Ricardo Campos Espinoza

Abril de 2012

Resumen

La correcta calificación de riesgo crediticio de un emisor es un factor crítico en nuestra actual economía. Profesionales y académicos están de acuerdo en esto, y los medios de comunicación han difundido mediáticamente eventos de impacto provocados por agencias de rating. Por ello, el trabajo de análisis del deudor realizado por expertos financieros conlleva importantes recursos en las empresas de consultoría de inversión y agencias calificadoras. Los investigadores, los teóricos y empíricos, no son la excepción a esta situación, sobre todo con el entorno económico y financiero que actualmente hay. Hoy en día, muchos avances metodológicos y técnicos permiten el apoyo a la labor que hacen los profesionales en la calificación de la calidad crediticia de los emisores. No obstante aún quedan muchos vacíos por completar y áreas que desarrollar para que esta tarea sea todo lo precisa que necesita.

Por otra parte, los sistemas de aprendizaje automático basados en funciones núcleo, particularmente las Support Vector Machines (SVM), han dado buenos resultados en problemas de clasificación cuando los datos no son linealmente separables o cuando patrones ruidosos se emplean para la tarea de entrenamiento. Además, al usar estructuras basadas en funciones núcleo resulta posible tratar cualquier espacio de datos, expandiendo las posibilidades para encontrar relaciones entre los patrones, tarea que no resulta fácil con técnicas estadísticas convencionales.

El propósito de esta tesis es examinar los aportes que se han hecho en la réplica de rating, y a la vez, examinar diferentes alternativas que permitan mejorar el desempeño de la réplica con SVM. Para ello, primero se ha revisado la literatura financiera con la idea de obtener una visión general y panorámica de los modelos usados para la medición del riesgo crediticio. Se han revisado las aproximaciones de medición de riesgo crediticio individuales, utilizadas principalmente para la concesión de créditos bancarios y para la evaluación individual de inversiones en títulos de renta fija. También se han revisado modelos de carteras de activos, tanto aquellos propuestos desde el mundo académico como los patrocinados por instituciones financieras.

Además, se han revisado los aportes llevados a cabo para evaluar el riesgo crediticio usando técnicas estadísticas y sistemas de aprendizaje automático. Se ha hecho especial énfasis en este último conjunto de métodos de aprendizaje y en el conjunto de metodologías usadas para realizar adecuadamente la réplica de rating.

Para mejorar el desempeño de la réplica, se ha elegido una técnica de discretización de las variables bajo la suposición de que, para emitir la opinión técnica del rating de las compañías, los expertos financieros en forma intuitiva evalúan las características de las empresas en términos intervalares.

En esta tesis, para realizar la réplica de rating, se ha usado una muestra de datos de compañías de países desarrollados. Se han usado diferentes tipos de SVM para replicar y se ha expuesto la bondad de los resultados de dicha réplica, comparándola con otras dos técnicas estadísticas ampliamente usadas en la literatura financiera. Se ha concentrado la atención de la medición de la bondad del ajuste de los modelos en las tasas de acierto y en la forma en que se distribuyen los errores.

De acuerdo con los resultados obtenidos se puede sostener que el desempeño de los SVM es mejor que el de las técnicas estadísticas usadas en esta tesis; y luego de la discretización de los datos de entrada se ha mostrado que no se pierde información relevante en dicho proceso. Esto contribuye a la idea de que los expertos financieros instintivamente realizan un proceso similar de discretización de la información financiera para entregar su opinión crediticia de las compañías calificadas.

Tabla de contenidos

Capítulo 1. Introducción.....	1
1.1 Motivación del trabajo.....	2
1.2 Objetivos de la tesis.....	3
Capítulo 2. El Riesgo de Crédito y el Rating Crediticio.....	5
2.1 Introducción.....	5
2.2 Conceptos básicos del riesgo de crédito.....	9
2.2.1 Tipologías de créditos.....	10
2.2.2 Aproximaciones al riesgo de crédito.....	12
2.3 Medición del riesgo crediticio individual.....	23
2.3.1 El Rating como medida de riesgo crediticio individual.....	23
2.3.2 Aproximaciones para la concesión de créditos bancarios.....	27
2.3.3 Dificultades de los modelos de concesión de crédito.....	40
2.4 Modelos que replican el rating.....	44
2.4.1 Relación entre rating y características de las compañías.....	46
2.4.2 Selección de las variables para replicar el rating.....	50
2.4.3 Virtudes y críticas de los modelos de réplica de ratings.....	53
2.5 La propuesta para replicar el rating en esta tesis.....	55
2.6 Resumen.....	59
Capítulo 3. Técnicas usadas en Riesgo de Crédito.....	60
3.1 Transformación de las variables.....	61
3.1.1 La transformación de las variables con una función.....	61
3.1.2 Discretización de variables continuas.....	62
3.1.3 Cambio de dimensionalidad.....	63
3.2 El conjunto de datos y las técnicas de validación.....	64
3.3 Elección de las técnicas predictivas.....	66
3.3.1 Sistemas de Aprendizaje Automático.....	68
3.3.2 Comparación entre las técnicas clasificatorias.....	84
3.4 Cuantificación de la bondad de la predicción.....	86
3.4.1 Tablas de contingencia y medición del nivel de aciertos.....	87
3.4.2 Curvas ROC y análisis AUROC.....	88
3.5 Comparación de resultados predictivos de rating crediticio.....	90
3.5.1 Resultados de las predicciones.....	94
3.6 La propuesta para replicar el rating en esta tesis.....	104
3.7 Resumen.....	106
Capítulo 4. La Muestra de Datos.....	109
4.1 Análisis descriptivo de las variables cuantitativas.....	112
4.2 Relaciones entre las variables cuantitativas y el rating.....	117
4.3 Análisis de las variables agrupadas.....	120
4.3.1 Agrupación por países.....	120
4.3.2 Agrupación por sector industrial.....	121
4.4 Evaluación de datos ausentes.....	124
4.5 Depuración de la muestra para replicar el rating en esta tesis.....	128

4.6	Resumen	128
Capítulo 5.	Aplicación de los SVM a la Réplica del Rating	131
5.1	Metodología utilizada para replicar	132
5.1.1	La selección de las variables	132
5.1.2	Técnicas empleadas para replicar el rating.....	135
5.1.3	Cuantificación de la bondad de la réplica.....	137
5.1.4	Calibración de parámetros en los SVM.....	138
5.1.5	La discretización de variables	140
5.2	Resultados de la réplica de ratings	143
5.2.1	Biclasificación con SVM.....	143
5.2.2	Resultados de la réplica de rating con 7 clases.....	146
5.2.3	Mejoras potenciales de la mejor SVR con datos discretizados	157
Capítulo 6.	Conclusiones y futuras investigaciones	161
6.1	Metodología utilizada para la réplica del rating	162
6.2	Réplica del rating con SVM	163
6.3	La elección del kernel y la calibración de sus parámetros	164
6.4	La discretización de variables es una tarea inconsciente que hacen los analistas financieros.....	165
6.5	Investigaciones futuras	165
Referencias	165
Anexos	183

Índice de Tablas

Tabla 1. Simbología y significado de rating de deuda de largo plazo	16
Tabla 2. Cuadro comparativo de modelos de medición de riesgo crediticio para carteras de bonos	19
Tabla 3. Resumen de aproximaciones usadas en la medición del riesgo crediticio	21
Tabla 4. Tasa promedio de fallido a un año de bonos con rating	24
Tabla 5. Matriz de transición: cambios porcentuales de ratings de Moody's de bonos (1920 a 1996)	24
Tabla 6. Probabilidades acumuladas de fallido a diferentes horizontes anuales (como porcentaje)	25
Tabla 7. Variables de algunos modelos con fines de predicción de quiebra en empresas	30
Tabla 8. Equivalencia entre ratings con grados de inversión y especulativo y su score medio	32
Tabla 9. Ejemplos de modelos de puntaje de corte para predicción de quiebra.	33
Tabla 10. Tasas de acierto de los fallidos en el tiempo (en %)	35
Tabla 11. Cuadro comparativo de modelos de concesión de crédito.	39
Tabla 12. Correlaciones entre tasas de fallido e indicadores económicos	44
Tabla 13. Variables de algunos modelos con fines de réplica de rating.	47
Tabla 14. Promedio de tasas de acierto según el N° de grupos de rating	50
Tabla 15. Artículos publicados de réplica de ratings	51
Tabla 16. Relaciones esperadas entre las variables de la muestra y el rating	57
Tabla 17. Artículos de predicción del riesgo crediticio individual con diferentes técnicas cuantitativas.	67
Tabla 18. Comparación entre tipos de técnicas clasificadoras	85
Tabla 19. Características de las variables de entrada y salida de las técnicas de clasificación.	86
Tabla 20. Matriz de confusión genérica	87
Tabla 21. Matriz de confusión	88
Tabla 22. Comparación de la AUROC de distintas técnicas y distintos conjuntos de datos	89
Tabla 23. Artículos publicados en los que hay clasificación de ratings de empresas no financieras	91
Tabla 24. Diferencias entre los porcentajes de acierto de cada técnica y la mejor técnica de predicción	103
Tabla 25. Ventajas y desventajas de las técnicas de clasificación presentadas en este capítulo.	107
Tabla 26. Distribución de rating de la muestra por país y grado de riesgo crediticio.	109
Tabla 27. Distribución de datos por países y sector industrial	111
Tabla 28. Variables financieras de la muestra que caracteriza a las compañías	112
Tabla 30. Estadísticos de los cuatro momentos para las variables de la muestra	113
Tabla 29. Tipo de relaciones visuales en la muestra entre las variables del rating	117
Tabla 31. Distribución de los datos vacíos	125
Tabla 32. Distribución por variable de missing values y de valores nulos	126
Tabla 33. Distribución de missing values de algunas ratios por sector industrial	127
Tabla 34. Ratios económico-financieros.	133
Tabla 35. Ejemplo de las relaciones que hay entre las variables y el rating	133
Tabla 36. Criterios estadísticos para incluir variables a un modelo de réplica de rating	135
Tabla 37. Matriz de confusión para explicar los niveles de los errores de réplica.	138
Tabla 38. Ejemplo de tasas de acierto según valores de parámetros de una SVR	140

Tabla 39. Intervalos finales para cada variable discretizada con el método CAIM.	142
Tabla 40. Parámetros óptimos para distintos kernels para la biclasificación y sus tasas de acierto.	145
Tabla 41. Tasas de acierto global con AD y logit en la tarea de biclasificación	145
Tabla 42. Cuadro resumen de los rangos más relevantes para cada parámetro	148
Tabla 43. Resumen de tasas de acierto, errores y simetría para M1 y M2 utilizando diferentes funciones núcleo, tanto dentro como fuera del conjunto de datos de entrenamiento.	150
Tabla 44. Parámetros usados para encontrar la réplica más eficiente con un kernel radial y M2 de acuerdo a las tasas de acierto total.	151
Tabla 45. Parámetros que hacen la réplica de rating con mayores niveles de acierto.	153
Tabla 46. Resumen de resultados de las mejores réplicas con diferentes técnicas	154
Tabla 47. Estadísticos de error de sobre y subestimación en la réplica, y su simetría.	155
Tabla 48. Demora media en entrenamiento.	156
Tabla 49. Desempeño la SVR con mejor desempeño M2 fuera de la muestra ($\gamma=0,1$; $C=15$)	158
Tabla 50. Mejores desempeños para cada kernel usando datos diferentes tipos de datos de origen.	159
Tabla 51. Tasas de acierto (%) en la réplica de rating con las técnicas usadas y sus mejores parámetros.	163

Índice de Figuras

Figura 1. Clasificación de créditos.....	11
Figura 2. Aproximaciones para medir el riesgo crediticio o alguno de sus componentes.....	13
Figura 3. Distribución de los 50 bancos más grandes según el número de clases de rating interno.....	37
Figura 4. Esquema del contexto de los ratings en esta tesis.....	45
Figura 5. Aspectos claves que se desarrollan en la réplica de rating.....	52
Figura 6. Ejemplo de un árbol de decisión para clasificar compañías.....	73
Figura 7. Ejemplos de clasificación binaria con una SVM.....	77
Figura 8. Gráfica de dos curvas ROC.....	89
Figura 9. Pasos en el proceso de réplica de rating.....	105
Figura 12. Distribución de datos de rating por sector industrial (izquierda) y por país (derecha).....	111
Figura 16. Histogramas de ratios de financiación y liquidez.....	113
Figura 17. Distancia entre la mediana y la media de las variables cuantitativas excluyendo a las de tamaño y volatilidad.....	115
Figura 13. Gráficos de barra de algunas variables respecto del rating en la muestra.....	118
Figura 14. Medianas de la variable a_vvtas de 2 sectores industriales agrupadas por rating.....	119
Figura 15. Medianas de l_c_cl de compañías de CYCGD y UTILS agrupadas por rating.....	119
Figura 18. Histogramas de la variable de financiación f_cf_td agrupada por país.....	120
Figura 19. Diagramas de caja de variables de financiación.....	122
Figura 20. Valor del rango de variables de liquidez agrupadas por sector industrial.....	122
Figura 21. Histogramas de la variable a_cf_s con y sin valores extremos.....	123
Figura 22. Diagrama de las fases experimentales realizadas durante la réplica.....	131
Figura 23. Comportamiento de tasas de acierto al cambiar parámetros de un kernel radial.....	139
Figura 24. Ejemplo de discretización de g_ronfa basado en CAIM.....	141
Figura 25. Comparación de la función de distancia para variable f_fa_ce , cambiando delta.....	141
Figura 26. Tasas de acierto para M2 a diferentes valores de C y gamma (g) para un kernel polinomial de grado 2.....	143
Figura 27. Tasas de acierto para M2 a diferentes valores de r y gamma (g) para un kernel sigmoide.....	144
Figura 28. Tasas de acierto a diferentes valores de r y gamma (g) para un kernel sigmoide con 32 variables... ..	144
Figura 29. Tasas de acierto y error con kernel sigmoide utilizando M2.....	147
Figura 30. Gráfica las tasas de acierto con kernel radial y sigmoide.....	151
Figura 31. Relación entre los parámetros de discretización y las tasas de acierto en la réplica.....	158

Capítulo 1. Introducción

Hoy la medición de riesgo es habitual y el riesgo crediticio no es la excepción. De su medición y gestión apropiada dependen diversos sistemas económicos, países, familias y expectativas individuales. Evidencias muy recientes de los efectos de decisiones inapropiadas en la gestión del riesgo crediticio hemos vivido desde inicios de este nuevo siglo. La crisis subprime, la gran crisis financiera mundial y, últimamente, la crisis de la deuda soberana europea aún están en la retina de muchos de nosotros. Pero ¿qué es el riesgo de crédito? En esencia, es el riesgo que surge cuando hay un préstamo y existe la posibilidad de que el prestatario no pague, no lo haga en las condiciones pactadas o cambie la calidad crediticia del deudor (Caouette, Altman y Narayanan, 1998; Peña; 2002).

Hoy existen muchos enfoques de como medir el riesgo crediticio. Algunos de ellos se orientan hacia la medición en carteras, mientras otros lo hacen en forma individual; algunos lo hacen con algún auspiciador corporativo, mientras que otros surgen por aportes académicos; algunos se orientan a la concesión de préstamos, mientras que otros a instrumentos bursátiles de renta fija. Entre todos ellos, el más reconocido es el rating crediticio, emitido por agencias calificadoras. Es una herramienta que se ha utilizado desde inicios del siglo XIX y que hoy se usa de manera amplia. Sin embargo, el rating hoy está en cuestionamiento debido a los serios problemas de credibilidad que han sufrido las agencias que lo emiten y sustentan, por profundos fallos y serios errores en las calificaciones de algunas compañías. Se ha criticado tanto el sistema de emisión como la motivación por la cual las agencias existen y funcionan. También se les ha cuestionado por la forma en que han actuado frente a circunstancias donde han participado tanto grandes compañías como países y la misma Unión Europea. No obstante todas estas críticas, los rating siguen siendo usados en el mercado financiero y presentan ventajas respecto de otros sistemas de medición del riesgo. Algunas de ellas son la simpleza en la comprensión y uso de los usuarios, y el hecho de que incorpora los dos tipos de riesgos crediticios definidos anteriormente.

Sin considerar las críticas a la metodología de cómo construir los rating, algunos autores (Bloechlinger, Leippold y Maire, 2012) proponen que cualquiera que sea el sistema que se use, a) éste debe funcionar razonablemente bien en momentos en que existan tensiones en los mercados, b) el sistema que se emplee debe ser transparente, sobre todo si se utiliza con fines de regulación y c) que dichas calificaciones correspondan a un momento del fecha única de tiempo y no a lo largo de un ciclo económico o período de tiempo. Otros autores recomiendan mejoras sistemáticas al sistema de

calificación crediticia (Hassan y Kalhoefer, 2011; Hilscher y Wilson, 2012). Tanto las críticas como el interés por el estudio de los ratings se debe a las implicancias que éstos tienen en nuestra economía y a lo mediático que ha resultado el debate.

1.1 Motivación del trabajo

Uno de los temas de investigación es la posibilidad de replicar el rating de forma automatizada. El primer estudio de réplica de rating se ha realizado en los años setenta (Horrigan, 1966), pero el interés por el rating en la última década se ha incrementado y los estudios de su réplica también (Shin y Han, 2001; Huang, Chen, Hsu, Chen y Wu, 2004; Lee, 2007, Ahn y Kim, 2011). En parte, este incremento se ha debido al uso de técnicas de inteligencia artificial para replicarlos. Pero este interés en la réplica de rating se debe fundamentalmente a lo importante que resulta el rating dentro de los sistemas de evaluación del riesgo crediticio en nuestra economías, a las críticas que han tenido las agencias de calificación crediticia y a que hay muchas compañías que no tienen la calificación crediticia emitida por algunas de las agencias de rating. Muchas empresas no tienen rating porque son pequeñas y no están dispuestas a pagar los servicios de la calificación, debido a lo costoso que resulta la solicitud a una agencia. En cualquier de estos casos, la información de su calidad crediticia es algo importante para sus acreedores. Por lo tanto, una importante pregunta es si acaso el rating puede o no ser replicado con alguna metodología y si ésta puede ser automatizada de alguna forma.

Desde los años sesenta, cuando se han hecho las primeras investigaciones de réplica de rating, se ha avanzado mucho, especialmente en los últimos 20 años. Uno de los motivos de ello se debe a los avances en novedosos y robustos métodos cuantitativos, y debido al alto desarrollo computacional que ha permitido que estos avances puedan llevarse a cabo de manera rápida y menos costosa. Los avances en técnicas de Inteligencia Artificial, y particularmente en *sistemas de aprendizaje automático*, han sido muy importantes en los últimos 25 años. Los sistemas aprenden a realizar predicciones mediante la estrategia de buscar patrones dentro de grandes conjuntos de datos con los que *entrenarse*. Uno de los primeros sistemas automáticos que se usaron en medición de riesgo crediticio fueron las redes neuronales (Dutta y Shekhar, 1988; Utans y Moody; 1991; Moody y Utans, 1994). Posteriormente, se han usado árboles de decisión, métodos basados en vecindad, técnicas de soft-computing y sistemas automáticos de soporte vectorial. Los sistemas automáticos de soporte vectorial (support vector machines, SVM) son sistemas diseñados inicialmente con fines clasificatorios, que han tenido éxito y gran desarrollo en los últimos 10 años; incluso con algunas aplicaciones en la réplica de rating. En esta línea, la investigación propiciada en esta tesis aporta evidencias acerca de si la réplica con SVM es apropiada y cómo puede implementarse.

Debido a que la emisión de rating en forma automatizada es una alternativa que cada vez parece más necesaria, esta tesis también aporta una discusión bibliográfica en esta línea, centrada en la réplica de rating crediticio corporativo para un grupo de países desarrollados.

1.2 Objetivos de la tesis

El objetivo central de esta tesis es realizar la réplica de rating corporativo con específicos sistemas automáticos de soporte vectorial. En esta tesis se entenderá por réplica de rating la capacidad de una determinada técnica de clasificar a una empresa en el rating crediticio, a partir de información económico financiera de la empresa.

En este sentido, el objetivo es medir la eficiencia de una determinada técnica para la réplica de rating, comparando los resultados obtenidos con los de otras dos técnicas estadísticas convencionales (análisis discriminante y regresión logística). Otro objetivo es evaluar una potencial mejora a la utilización de SVM mediante la discretización de las variables de entrada. Esta discretización se basa en la idea de que cuando los expertos humanos emiten su opinión financiera piensan más en intervalos que en valores.

Esta tesis está organizada como sigue:

En los capítulos 2 y 3 se expone una revisión conceptual y bibliográfica del riesgo crediticio, concentrándose en la réplica de rating. En el capítulo 4 se expone la muestra de datos y en el capítulo 5 la metodología de la réplica y los resultados de la misma. En el capítulo 6 se exponen las conclusiones finales de esta tesis. Finalmente, se adjuntan a estos capítulos las referencias y los anexos. Al final de los capítulos 2, 3 y 4, también se exponen, en forma resumida las decisiones metodológicas que el autor de esta tesis toma respecto al proceso de réplica, sobre la base de la revisión bibliográfica y la revisión empírica de los datos de la muestra, y que terminan por conformar parte esencial de la réplica del rating.

En el capítulo 2 se expone una revisión histórica y conceptual de las distintas aproximaciones que se usan para medir el riesgo de crédito, tanto aquellos usados por inversionistas institucionales, la banca y propuestas que provienen desde la academia. También se revisan las aproximaciones de medición de riesgo crediticio individuales, centrando la atención en estudios realizados en el ámbito de la réplica de rating. Luego de concluir la revisión de investigaciones realizadas de la réplica de rating, se exponen las tareas necesarias para realizar dicha réplica. Para realizar esta tarea de réplica de ratings el autor

indica qué tipo de rating se utiliza, qué tipo de datos son necesarios para realizar la réplica, qué granularidad se necesita, y cuáles han sido las técnicas utilizadas para realizar esta réplica.

El capítulo 3 revisa las distintas técnicas que se han usado en la literatura para replicar el rating. Dichas técnicas se refieren a la evaluación de al menos los siguientes cinco puntos: (a) elegir la técnica clasificatoria más adecuada; (b) decidir si es pertinente la transformación de las variables; (c) elegir la técnica de validación; (d) elegir las herramientas que permitan realizar las mediciones de la bondad de la tarea predictiva; y (e) seleccionar el conjunto de datos.

El capítulo 4 expone los principales resultados del análisis exploratorio y descriptivo de una muestra de datos para replicar el rating. Este conjunto de datos contiene información del año 2002 de compañías de países desarrollados. Los datos financieros que ayudan a la réplica se refieren a las condiciones estructurales, de gestión y variabilidad bursátil de las compañías. Este conjunto de datos estudiado es apto para la tarea de réplica y no se observan anomalías significativas que perturben la interpretación de los resultados.

El capítulo 5 expone la metodología usada para realizar la réplica de rating y los resultados que se han obtenido. Dentro de la metodología se muestran los criterios y pasos seguidos en la selección de los kernels, la calibración de los parámetros usados y el procedimiento llevado a cabo en la discretización de los datos de las variables. En esta metodología se distinguen 3 fases: la primera es la fase de réplica preliminar con un proceso de biclasificación, la segunda fase incluye los ajustes del proceso anterior y la réplica del rating en 7 clases, y la fase 3 corresponde a la discretización de las variables, como una propuesta de mejora del proceso de réplica.

El capítulo 6 exhibe las conclusiones respecto del proceso de réplica de rating y las futuras investigaciones relacionadas con la tesis.

Capítulo 2. El Riesgo de Crédito y el Rating Crediticio

Este capítulo ofrece un conjunto de definiciones y conceptos vinculados con el riesgo que un acreedor tiene al conceder crédito a terceros. Luego de introducir las motivaciones por las cuales este riesgo es importante, en la sección 2.2 se entregan los conceptos básicos para comprenderlo. Finalmente, en la sección 2.3 se exponen las distintas aproximaciones que hoy existen para la medición del riesgo por otorgar crédito.

2.1 Introducción

El crédito es una antigua operación y a la vez es una función de suma importancia en la sociedad actual. La evidencia más antigua conocida de concesión de créditos está en registros babilónicos del código de Hamurabi, que datan hace más de 4000 años atrás. Es probable que debido a lo antigua que es esta operación, hoy el crédito es una pieza clave de los sistemas económicos en la mayoría de los países y mercados; permitiendo que personas y organizaciones con excesos de fondos puedan transferirlos a quienes tienen déficit de efectivo, a cambio de una recompensa y de la obligación de devolver los fondos. Este tipo de operaciones ayuda a incrementar la riqueza y satisfacción de las personas, debido a que posibilita la financiación de actividades y proyectos que no podrían llevarse a cabo sin esta transferencia de fondos. Sin embargo, durante la realización de los proyectos ocurren eventos inesperados que pueden causar que la devolución de fondos no se materialice en la forma acordada o, aun más, ni siquiera se recuperen dichos fondos. Esto causa pérdidas al inversionista por el monto no recuperado y por los costes asociados al intento de recuperación. Este es el principal riesgo que corre el acreedor en las operaciones crediticias y su adecuada evaluación es una tarea de gran importancia para el acreedor. Se trata del *riesgo de crédito*.

Desde siglos el hombre ha enfrentado la decisión de otorgar crédito evaluando la confianza que tiene en el solicitante y la posibilidad de que éste devuelva lo concedido según lo acordado previamente. Quizás por ello la raíz etimológica de la palabra crédito haga referencia a la confianza que hace el propietario del bien en préstamo: la palabra *creditum* significa “algo confiado a otro; préstamo” (Merriam Webster, 1997). Desde los primeros indicios de operaciones de crédito, el hombre sólo se limitaba a consignar las operaciones crediticias para mantenerlas en registro, como una manera de control. Debido a la baja complejidad de la decisión y al fácil control de los deudores, aparentemente, no existía la necesidad de un sistema de medición de riesgo por incumplimiento de las deudas. Posteriormente, en los antiguos grandes imperios y civilizaciones (egipcio, fenicio, griego, helénico y,

finalmente, romano) el registro de operaciones y hechos económicos tomó un importante papel, sin que hubiese un desarrollo de metodologías de medición del riesgo por incumplimiento. Durante diferentes estadios históricos sólo se perfeccionó el proceso de registro y valoración de la deuda; por ejemplo, a través de la creación de métodos de registro sistematizados para medir los pasivos de la actividad comercial, tanto en órdenes religiosas como en algunos gobiernos locales europeos en la Edad Media (Jeacle, O'Hogartaigh y O'Hogartaigh, 2000). Estas mejoras en los sistemas de medición y registro de operaciones mercantiles ayudaron a medir relaciones (ratios) de patrimonio y deuda de una manera más fiable, y así colaborar en la estimación intuitiva del riesgo que corría el acreedor.

Durante la Revolución Industrial, provocado por las necesidades de fondos de las compañías en plena fase de expansión, la evaluación crediticia de los solicitantes de dinero de instituciones financieras era cada vez más difícil, ya que el control de los deudores era cada vez más complejo. Luego, en países industrializados, se incrementó la participación de las instituciones financieras como suministradores de capital e información financiera para la expansión de los negocios, y aumentó la demanda de información que ayudase a realizar la evaluación crediticia y de inversión. Por ejemplo, la crisis financiera de 1837 en EUA impulsó el desarrollo de sociedades que vendían información financiera (Raimbourg, 1990). Las primeras de estas sociedades en fundarse fueron The Mercantile Agency (en 1841) y Branstreet's Improved Commercial Agency (en 1849). Estas y otras compañías generaban manuales con datos estadísticos con información financiera y crediticia de algunas compañías, lo que luego se fue sintetizando en un indicador de la calidad crediticia o de pago del deudor. Este ha sido un sistema preliminar e intuitivo de rating, donde no sólo importaba la posibilidad de que el deudor no pagase la deuda, sino que también el impacto en los precios de las acciones y bonos, provocado por los cambios de su calidad crediticia. Esta es una importante diferenciación en la caracterización del riesgo crediticio.

A partir de mediados del s.XX la banca y distintas compañías que concedían crédito intensificaban esfuerzos para contar con metodologías estandarizadas para la selección de crédito. Esto motivó a algunos investigadores a utilizar técnicas estadísticas con la finalidad de explicar o predecir los fallidos. En un proyecto del National Bureau of Economic Research, en 1941 Durand fue uno de los pioneros que utilizó una de estas técnicas¹ para diferenciar clientes de créditos de consumo que cumplían con el pago de su deuda de aquellos que no lo hacían. En años siguientes, los trabajos de Beaver (1966), Altman (1968), Edminster (1972) y Blum (1974), utilizaron análisis discriminante con datos de compañías industriales en quiebra, con la intención de utilizar esta técnica estadística para la predicción de quiebras corporativas. A partir de entonces, el uso de técnicas de clasificación para la concesión de créditos se intensificó, lo que significó un gran apoyo a la industria bancaria. Esta línea

¹ En dicha oportunidad se usó análisis discriminante, que es una técnica estadística que permite clasificar grupos de datos, basándose en las diferencias existentes entre ellos. Para mayores antecedentes acerca de la técnica se recomienda a Hair, Anderson, Tatham y Black (1999).

de investigaciones, en forma implícita, define que el riesgo de crédito sólo está en función de la posibilidad que el deudor no pague sus deudas.

Frente al desarrollo de metodologías para la predicción de quiebras y malos deudores, surge una diferente línea de investigación para medir el riesgo crediticio. Merton (1974) marca un hito importante al proponer un modelo que plantea que los bonos y las acciones de una compañía pueden ser vistos como derechos contingentes sobre los activos de la empresa. Otra línea de investigación es la que han seguido los modelos que tratan el fallido como un hecho inesperado, en forma independiente de la estructura de capital de la compañía (Litterman e Iben, 1991; Jarrow y Turnbull, 1995; Jarrow, Lando y Turnbull, 1997).

Paralelamente, y como respuesta a la necesidad de inversionistas con carteras de inversiones crediticias, para medir el riesgo de crédito, algunas compañías financieras comenzaron a crear modelos cuya finalidad era determinar distribuciones de pérdidas de los portfolios de los inversionistas: en 1993 la empresa KMV presenta Portfolio Manager; J.P. Morgan presenta en 1997 CreditMetrics; y también en 1997 Credit Suisse Financial Products y McKinsey presentan CreditRisk+ y CreditPortfolioView, respectivamente. Con esta evaluación agregada de la cartera crediticia los inversionistas pueden concluir políticas para la compra o venta de determinados títulos, o para cambiar la diversificación de una determinada cartera.

Otra influencia importante en la medición del riesgo de crédito han sido las crisis financieras de inicios de este nuevo siglo. Las crisis más relevantes han sido la *crisis subprime* (desde 2006), la *gran crisis financiera mundial* (desde 2008) y últimamente la *crisis de la deuda soberana europea* (desde 2010). De ellas, la más seria y profunda es la crisis financiera mundial y que es considerada por muchos economistas como la peor crisis financiera desde la Gran Depresión de la década de 1930 (Yergin, 2009; Fosler, 2011). Estas crisis han generado diversas dificultades, pero en el ámbito crediticio han creado problemas de solvencia bancaria, han restringido la disponibilidad de crédito y han causado el descenso de la confianza de los inversores. Además, ha quedado de manifiesto los problemas de valoración y liquidez de productos financieros de alto riesgo, los conflictos de interés no revelados al público, fracasos en el cumplimiento del objetivo de los reguladores, de agencias de calificación crediticia y del propio mercado al no frenar los excesos de instituciones financieras y sus altos ejecutivos (Declaración del G20, 2008; Simkovic, 2009; Ivry, 2008; The Financial Crisis Inquiry Commission, 2011; Levin y Coburn, 2011; Esterhuysen, van Vuuren y Styger, 2011). Con todo esto, la credibilidad en las agencias de rating ha disminuido fuertemente, aunque esto no signifique que el sistema de calificación esté inhabilitado. También se ha colocado en un punto de mira a otros organismos reguladores. Incluso, se ha cuestionado la validez y pertinencia de los principios subyacentes de evaluación del riesgo de crédito bancario elaborados por el Bank for International

Settlements (BIS) y que conforman la base del Acuerdo de Capital vigente o Basilea II (BIS, 2003, 2004). Estos principios han sido concebidos para proporcionar a los bancos y otras instituciones financieras métodos de gestión de riesgo de crédito y una guía para su evaluación, donde se plantea que el capital bancario requerido dependa del riesgo crediticio de su cartera. Sin embargo, hay evidencias de que con aplicación de Basilea II los niveles de capital de algunas instituciones son inadecuados durante crisis y, por lo tanto, sus principios son cuestionables (Colander, Follmer, Haas et al., 2009; Rajan, Seru y Vig, 2010). Por todo ello, la aplicación de nuevas reglas para el fortalecimiento de las regulaciones y sistemas de prevención bancarios, que se aplicarán paulatinamente desde 2012 (BIS, 2009, 2010, 2011; Härle, Lüders, Pepanides, et al., 2010; Chabanel, 2011), serán observadas con mayor detención.

Por otro lado, otra crisis que ha mermado la confianza de los sistemas de medición de riesgo crediticio ha sido la crisis de la deuda soberana de la Eurozona. Ésta es una serie de acontecimientos que han afectado desde 2010 a los 16 estados de la UE que adoptaron el euro. Hasta hora, la mayor polémica y los problemas de mayor importancia se han debido al déficit y nivel de la deuda pública de Grecia, seguidos por una combinación de factores entre los que se cuentan las malas prácticas bancarias y endeudamiento arriesgado, las burbujas inmobiliarias, los desequilibrios en el comercio internacional, entre otros (Lewis, 2011). Aun más, las tres agencias de calificación más importantes del mundo, Moody's, Standard & Poor's y Fitch, que ya habían sido criticadas durante la burbuja inmobiliaria global, también han sido acusadas de haber otorgado calificaciones con conflictos de interés. También se les ha criticado su actuación demasiado conservadora en función de los intereses con sus clientes (Warner, 2010).

Existen diversas aproximaciones para medir el riesgo crediticio, tanto por el impago como por el riesgo de que la calidad crediticia del deudor disminuya. Las diferentes aproximaciones de medición del riesgo de crédito responden al propósito de dos de los actores más relevantes en medición de riesgo de crédito: la banca y los inversionistas institucionales que transan títulos de deuda. La banca tiene tres grandes motivaciones para medir el riesgo crediticio de sus deudores. Primero, para decidir si concede o no crédito a sus clientes, motivo por el cual la banca suele clasificar a sus clientes de acuerdo a su riesgo. Segundo, la medición del riesgo crediticio es importante para asignar tipos de interés adecuados al riesgo de sus clientes. A mayor riesgo de un cliente mayor es la tasa de interés que se le exige. Este diferencial de tasas ayuda a cubrir las reservas totales que el banco debe mantener para hacer frente al impago. Por último, y desde una perspectiva agregada, la medición del riesgo crediticio es útil para tomar las necesarias provisiones en la cartera por las pérdidas esperadas y reservas en caso de que las pérdidas sean inusualmente mayores. Una adecuada gestión de una cartera requiere que el capital disponible sea suficiente para mantener el nivel de actividades, asumiendo pérdidas esperadas e inesperadas para un período de tiempo concreto. Como lo ejemplifica Marrison

(2002, pág.229): si para una cierta magnitud de riesgo crediticio el capital es insuficiente, entonces el “banco debería incrementar su capital, reducir el riesgo o esperar que su calificación crediticia sea bajada”. En esta línea, el BIS propone reformar la regulación a los bancos de países desarrollados con el Nuevo Acuerdo de Capital y sus nuevas modificaciones conocidas como Basilea III.

También es importante la adecuada medición del riesgo crediticio para los inversionistas institucionales, como las aseguradoras y las compañías de inversión colectiva, ya que les permite decidir en qué tipo de títulos de deuda invertir, y así optimizar la relación de riesgo y rentabilidad de sus carteras. Para este tipo de inversores, la adecuada medición del riesgo individual y de toda la cartera crediticia incluye el cálculo de la distribución de pérdidas, para un momento dado del tiempo; es decir, el cálculo de las probables pérdidas que pueden ocurrir en un periodo de tiempo, provocadas por la disminución del valor del portfolio a causa de impagos o de la disminución del valor de los activos individuales, causada por el deterioro de la calidad crediticia del deudor.

2.2 Conceptos básicos del riesgo de crédito

Actualmente no existe una única definición de lo que significa el riesgo crediticio. Una primera acepción de riesgo de crédito es la que recogen Caouette et al. (1998, pág. 1) cuando plantean que “si el crédito es la esperanza de la suma de dinero dentro de algún tiempo limitado, entonces el riesgo de crédito es la posibilidad que esta expectativa no se cumpla”. Este riesgo es “...una consecuencia de contratos y/o transacciones financieras contingentes entre proveedores y demandantes de fondos” (Caouette et al., 1998, pág. 3). Desde esta definición, se manifiesta la importancia que tienen las expectativas futuras de que se materialice el cobro de una cantidad de dinero en una fecha pactada en el contrato. Es decir, el riesgo crediticio surge por la posibilidad de “que una pérdida ocurra cuando la contraparte de una transacción no cumple sus obligaciones financieras de una manera oportuna” (Arvanitis y Gregory, 2001, pág. 413). Este incumplimiento suele ocurrir por la “... insolvencia o falta de capacidad de pago genérica de la parte deudora” (del Águila, Cortés, Fernández y García, 2002, pág. 19), y puede deberse a problemas financieros que llevan al deudor a no pagar el principal, el interés o toda la cuota, y que pueden desencadenar la restructuración de su organización o su quiebra. Sin embargo, debido a que la normativa de cada país define estas situaciones de diversas maneras, las definiciones de impago, restructuración y quiebra no resultan homogéneas, aunque todas originan la incapacidad de cumplir el pago de obligaciones, provocando pérdidas en el acreedor.

Un segundo tipo de definición de riesgo crediticio incorpora además del riesgo por incumplimiento, la eventual ocurrencia de pérdidas por los cambios de la calidad crediticia del deudor. Siguiendo a Peña (2002, pág. 121), el riesgo de crédito es aquella posibilidad de que ocurran “pérdidas asociadas al evento de fallido del prestatario o al evento del deterioro de su calidad crediticia”. En la medida que la

calidad crediticia del deudor cambia, el mercado suele corregir los precios de sus instrumentos de deuda. Entonces, esta pérdida de valor en los valores mobiliarios provocados por el descenso de la calidad crediticia queda incluida en la definición de riesgo de crédito.

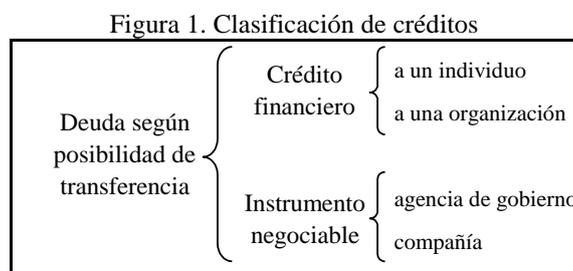
La elección de la definición de riesgo de crédito depende de la relación que existe entre el acreedor y el deudor, y de la forma contractual de la deuda. La relación entre quien concede los fondos y quien los recibe, queda formulada según la intención que persigue el proveedor de fondos, las posibilidades jurídicas y las prácticas de mercado. En la medida que el proveedor de fondos desee establecer una relación de permanencia y continuidad con el deudor, entonces la definición de riesgo crediticio sólo debería incluir el riesgo por incumplimiento de dicha obligación y debería descartarse la evaluación de pérdidas por el cambio de la calidad crediticia del deudor. Esta situación ocurre cuando el cobro de la deuda sólo se efectúa al final del vencimiento, y el deudor no necesita, o no tiene la posibilidad de transferir la deuda en el mercado, como por ejemplo en el común crédito bancario. En cambio, si la intención del proveedor de fondos, el acreedor, es mantener la posibilidad de transferir la deuda en cualquier momento (antes o durante del vencimiento), entonces la definición adecuada de riesgo crediticio será aquella que, además de incluir el riesgo de impago, incorpore la posibilidad de pérdidas por cambio en la calidad crediticia del deudor. Esta diferenciación de conceptos deja en evidencia cuán importante es definir la relación de crédito y tipo de contrato que se está evaluando. Por ello, en la siguiente sección se revisan los principales tipos de créditos y cuáles interesan en esta memoria.

2.2.1 Tipologías de créditos

Atendiendo a la naturaleza de la relación contractual entre quien aporta los fondos y quien los recibe, se pueden diferenciar dos tipos básicos de créditos: el comercial y el exclusivamente financiero. En el crédito comercial, existe una relación periódica, derivada de un vínculo mercantil. El principal objetivo del crédito es servir de puente para mantener y fortalecer el vínculo cliente-proveedor de bienes o servicios. En otras palabras, el riesgo más importante que asume el proveedor de fondos es de tipo comercial. En el crédito financiero, a diferencia del comercial, existe una exclusiva relación de financiamiento de recursos y, por tanto, el riesgo asumido es exclusivamente de crédito. Es éste el riesgo que interesa en este trabajo y que será objeto de estudio. En lo sucesivo, toda referencia al crédito se referirá al de tipo financiero.

De acuerdo a la capacidad de transferir la titularidad, los contratos de deuda pueden ser (i) intransferibles o (ii) negociables en mercados secundarios. Los créditos intransferibles son concedidos por una institución financiera (ver Figura 1), mientras que los contratos de deuda negociables son instrumentos por los cuales un inversionista entrega una cantidad de dinero, principalmente a través de bonos. La titularidad de un crédito puede ser o no transferible en función de

(i) si el demandante de recursos tiene acceso a un mercado secundario que le permita la negociación, (ii) de la existencia de una estructura jurídica que lo permita y (iii) del volumen del crédito requerido. La transferencia de créditos no sería posible si un mercado secundario, o si no existiesen contratos de deuda adecuados. Además, si el volumen de la deuda a solicitar no es suficiente o si la compañía que necesita los recursos no cumple las exigencias legales, ésta sólo podrá optar a solicitar el crédito a una institución financiera, en lugar de emitir títulos de deuda.



Fuente: Elaboración propia.

Los créditos intransferibles, o condicionalmente transferibles, son otorgados por: (1) intermediarios financieros bancarios, (2) por instituciones financieras no bancarias que otorgan crédito sobre la base de los fondos de sus ahorradores, y (3) por entidades que no sean instituciones de crédito, pero cuya actividad principal consista en la concesión de créditos individualizados, y que incluye a compañías de emisión y gestión de tarjetas de crédito, a las de factoring y a las de concesión de avales, garantías o suscripción de compromisos similares. Las principales características de los intermediarios financieros bancarios son (i) que gran parte de sus pasivos son monetarios y (ii) que pueden generar nuevos recursos financieros (mientras que las instituciones no bancarias no pueden crear recursos monetarios). De estos tres tipos de intermediarios del mercado financiero la banca ha sido y sigue siendo uno de los principales integrantes que, por la naturaleza de su actividad comercial, gran parte del riesgo que captura es crediticio. Aun más, puede considerarse que su principal actividad es la gestión del riesgo crediticio.

Por otra parte, los instrumentos de deuda son contratos que demuestran que el tenedor ha suministrado una cantidad específica de dinero a una compañía o a una agencia gubernamental y se espera que sean reembolsados con el interés a una fecha específica. Estos títulos-valor varían respecto de su garantía, su finalidad de financiamiento, la capitalización de su tasa de interés y la manera como se estipula la remuneración de la deuda. Los instrumentos más conocidos son los bonos corporativos, los bonos soberanos, los debentures o cédulas y los pagarés, aunque la normativa y las costumbres cambian entre países. Las principales entidades que invierten en este tipo de activos son las compañías aseguradoras e instituciones de inversión colectiva. Las compañías de seguros se caracterizan por acumular importantes reservas que invierten en instrumentos de deuda. En EUA el 64% de todas las inversiones crediticias en 1995 fueron realizadas por aseguradoras, e instituciones de inversión colectiva (Caouette et al., 1998); mientras que en España las aseguradoras invirtieron en títulos de deuda en 1995 el 66%

de sus activos y los fondos de pensiones lo hicieron en un 82%. A fines de 1994 en Europa los fondos de pensiones invertían en promedio un 58% de sus activos totales en estos instrumentos de renta fija (Casilda, Lamothe y Monjas, 1996).

Atendiendo a quien recibe los fondos en la operación de crédito, las instituciones financieras que otorgan préstamos pueden concederlos a individuos o a organizaciones (ver Figura 1), mientras que en las transacciones de instrumentos de deuda los receptores de fondos son principalmente compañías o agencias de gobierno.

Por último, en esta tesis se han ido descartando paulatinamente el estudio de determinados tipos de créditos con la finalidad de concentrar la atención en un problema más homogéneo. En lo consecutivo, cualquier alusión a un contrato de deuda se entenderá que se refiere a un crédito financiero (no comercial) concedido a una compañía.

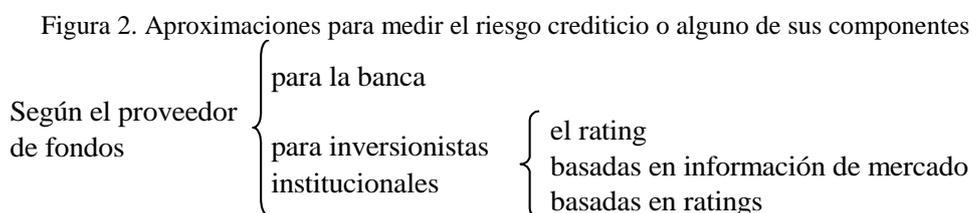
2.2.2 Aproximaciones al riesgo de crédito

La principal inquietud de un acreedor es que el deudor pague la deuda según lo acordado. Es decir, al proveedor de fondos (banca o inversionista institucional) le preocupa sobre todo la pérdida monetaria producto de potenciales impagos. Este es el principal componente del riesgo crediticio. Este cuidado por las pérdidas es vital tanto a nivel de deudas individuales como a nivel agregado de la cartera de deudas. Pero cuando se trata de carteras, es más importante el efecto neto en la valoración total del portfolio que la determinación individual de pérdidas.

Otro componente de importancia en el riesgo de crédito es el cambio de la calidad crediticia del deudor. Dicho cambio de la calidad crediticia ocurre cuando las posibilidades de que no cumpla el pago de su deuda varían. Es decir, factores externos al deudor y/o su situación financiera, fundamentalmente de liquidez y solvencia, se ha visto modificada. El cambio de calidad crediticia negativo es el que más interesa al acreedor, debido a que si esto ocurre el precio del instrumento de deuda es castigado, provocando pérdidas en el valor de la cartera del acreedor.

En el mercado financiero, tanto la banca como los inversionistas institucionales, es usualmente aceptada la convicción de que las pérdidas medias o esperadas queden cubiertas con los ingresos corrientes. Por lo tanto, para evitar problemas de quiebras bancarias o de los inversionistas institucionales, éstos deben contar con capital y reservas que sirvan para enfrentar pérdidas inusuales asumiendo un nivel de confianza, desestimando potenciales pérdidas residuales por las cuales existe una bajísima probabilidad de ocurrencia. De acuerdo al nivel de confianza que la banca o inversionista elija, los evaluadores le otorgarán mayor o menor calificación crediticia.

Para conocer la distribución de pérdidas se hace necesario medir el riesgo crediticio y sus componentes, de los cuales la probabilidad de impago o la probabilidad de cambio de calidad crediticia son los elementos más importantes. Sobre estos componentes, tanto en la práctica financiera como en la académica, se han centrado los esfuerzos para medir el riesgo de crédito en las últimas tres décadas. Las aproximaciones para medir este riesgo son tan amplias y diversas que incluyen métodos que usan fundamentalmente el juicio de expertos financieros hasta aproximaciones basadas en complejas técnicas matemáticas y econométricas. Hay aproximaciones que se concentran en un crédito individual, como los métodos de scoring para la concesión de crédito; mientras que otras aproximaciones tienen su foco central en la distribución agregada de pérdidas de la cartera. Las técnicas de medición del riesgo crediticio responden a la naturaleza del acreedor y del instrumento financiero que soporta la deuda, y se pueden clasificar de la siguiente forma:



Fuente: Elaboración propia.

Este capítulo se centrará en aquellas aproximaciones usadas por la banca para la concesión de créditos a sus clientes y las utilizadas por inversionistas de títulos de deuda. Los inversionistas en bonos pueden elegir entre la medición directa del rating de agencias, aquellas aproximaciones basadas en información de mercado y los modelos de carteras basados en ratings. A continuación se presenta una visión general de estas aproximaciones.

2.2.2.1 La concesión crediticia bancaria

Para la banca el riesgo crediticio es parte importante de su negocio, por lo que la medición del riesgo por impago y el cálculo de la distribución de pérdidas son factores claves para la adecuada gestión de su cartera crediticia. Adicionalmente, el BIS propone reformar la regulación a los bancos de países desarrollados y el acuerdo de Basilea II pide a la banca que incorpore en la medición del riesgo crediticio el riesgo por impago, el riesgo por cambio de calidad crediticia y el efecto del grado de diversificación de su cartera. Entonces la banca debe ajustar su capital requerido en función del riesgo crediticio, el que debería expresarse a través de la distribución de pérdidas monetarias de su cartera.

Un aspecto fundamental para medir correctamente la distribución de pérdidas es tener en cuenta el efecto de la diversificación de la cartera. En un portfolio la distribución de fallidos dependerá no sólo de los valores de las probabilidades de fallido de cada deudor, sino que además de sus probabilidades

conjuntas. Esto ocurre debido a que los eventos que inciden en el riesgo de crédito no son independientes entre sí. Es decir, existe la posibilidad que el incumplimiento de un deudor (a) gatille fallidos de otros deudores de la misma cartera, o (b) que ambos deudores estén afectados por factores comunes de fallido que están conducidos por la naturaleza del deudor y por factores aun más generales del entorno. Otro aspecto que la banca debe tomar en cuenta para la medición del riesgo para una cartera se refiere a los efectos que causan los acuerdos de garantías y los acuerdos de compensación.

Como ya se ha comentado anteriormente, para obtener la distribución de pérdidas el banco necesita conocer la composición individual de pérdidas posibles. Para medir lo que el banco espera perder en forma individual para cada crédito, o sea, la pérdida esperada, es necesario contar con tres elementos: la probabilidad de fallido (PD, de las siglas de probability of default), la exposición y la recuperación en caso de fallido. De estos tres elementos, la PD es la más importante debido a que además sirve, directa o indirectamente, para la concesión de créditos. La banca puede determinar la PD de diversas maneras, pero todas las aproximaciones se basan en información financiera del cliente, datos del mercado y de la relación histórica que existe con el cliente. Con estos datos y el uso de alguna técnica matemático-estadística (como análisis discriminante, logit o redes neuronales, las cuales son discutidas en el próximo capítulo) es posible calcular la PD. Otra alternativa para obtener la PD es a través de las tasas promedio de incumplimiento de clientes con similar grado o clase de riesgo. A esta segmentación ordinal en grupos o clases de su clientela se conoce como rating interno. El número de clases no es el mismo para todas las instituciones financieras, pero por lo general, los bancos no utilizan más de 6 o 7 clases para tipificar a sus clientes. Según Treacy y Carey (1998), casi el 80% de los bancos en EUA utilizan entre 4 a 6 clases.

El segundo elemento necesario para calcular la pérdida esperada, EL (por las siglas de Expected Loss), es el monto otorgado en el crédito expuesto al evento de fallido (la exposición): es el grado de vulnerabilidad que tendrá el suceso en caso de ocurrir el fallido, y se refiere a los límites establecidos por el banco para restringir el alcance máximo de pérdidas. Y por último, en el caso de fallido, desde la EL debe excluirse aquella parte recuperada del crédito. Esto ocurre porque el banco suele recuperar una proporción del nocional (RR, siglas de Recovery Rate), la que suele ser expresada como

$$RR = \frac{\text{Monto recuperado en evento de fallido}}{\text{Valor del crédito adeudado}} \quad \text{Ecuación 1}$$

Con la RR es posible conocer la potencial pérdida sufrida en caso de fallido (LGD, por las siglas de Loss Given Default), que no es más que $LGD = 1 - RR$, con lo cual la pérdida esperada para cada crédito se calcula como sigue

$$EL = \text{exposición} * LGD * PD \quad \text{Ecuación 2}$$

Un problema importante para la banca es tener un sistema que permita cumplir con las exigencias de Basilea II, es decir, que las entidades financieras midan el riesgo de crédito de sus carteras mediante la cuantificación en unidades monetarias basándose en la distribución de pérdidas de su cartera. Por ello, el BIS fomenta el desarrollo de modelos internos que permitan estimar adecuadamente la distribución de pérdidas crediticias de una cartera. Una solución que se baraja es que la banca adopte modelos utilizados por inversionistas institucionales para la medición del riesgo de crédito de carteras de bonos. Las aproximaciones usadas para este tipo de contratos de deuda son esquematizadas a continuación.

2.2.2.2 Las inversiones en instrumentos de deuda

Para los inversores en instrumentos negociables de deuda el riesgo de crédito está directamente relacionado con la medición del riesgo por impago y del riesgo por el cambio de la calidad crediticia del deudor. En la medida que el inversor cuente con una cartera de títulos de deuda el cálculo de la distribución de pérdidas es un elemento clave para la gestión de su cartera. A diferencia de la gestión crediticia bancaria, a los inversores en títulos negociables les interesa adicionalmente el cambio de la calidad crediticia del deudor, debido a que éste incide en la valoración que tienen los instrumentos negociables en el mercado y, por tanto, en el rendimiento de la cartera.

La medición de riesgo de la cartera es similar a la que se puede llevar a cabo con deudas bancarias, pero las diferencias radican en la fuente de datos y las implicaciones de la forma que toman los contratos de deuda. Por ejemplo, para la medición del riesgo crediticio de bonos es inusual la existencia de acuerdos de compensación y de garantía, pero si es importante el grado de seniority o preferencia en la exigibilidad que tienen diferentes instrumentos de deuda transable. Dicha medición puede entenderse desde una perspectiva individual y desde una perspectiva agregada o conjunta. En la visión individual el rating emitido por una agencia externa es la forma más clásica y ampliamente usada para medir el riesgo de crédito de instrumentos de deuda en forma individual. Siguiendo a López (1996, pág.25), el rating es un “indicador de referencia expresivo de la mayor o menor capacidad o probabilidad de pago en el tiempo estipulado, tanto de los intereses como de la devolución del principal...” que se hace de un contrato de deuda o de la posición financiera de una organización.

Los ratings se representan a través de una escala con símbolos, de tal manera que éstos indiquen cuan posible es que los deudores incumplan en sus obligaciones de deuda. La Tabla 1 muestra las etiquetas de rating utilizadas por S&P y Moody's para la deuda de largo plazo.

Tabla 1. Simbología y significado de rating de deuda de largo plazo

Rating con grado de inversión			Rating con grado de especulación		
S&P y otros	Moody's	Interpretación de calidad	S&P y otros	Moody's	Interpretación de calidad
AAA	Aaa	La más alta calidad; es extremadamente fuerte	BB+	Ba1	Es posible que cumpla los pagos; con incertidumbre continua
AA+	Aa1	Alta calidad	BB	Ba2	
AA	Aa2		BB-	Ba3	
AA-	Aa3		Fuerte capacidad de pago	B+	B1
A+	A1	B		B2	
A	A2	B-		B3	
A-	A3	Adecuada capacidad de pago	CCC+	Caa1	Es vulnerable al fallido
BBB+	Baa1		CCC	Caa2	
BBB	Baa2		CCC-	Caa3	
BBB-	Baa3		CC		
			C		Quiebra solicitada, pero paga su deuda
			D	Ca	En quiebra o fallido

Fuente: Tabla basada en Caouette et al. (1998), tabla 6.3 y en Standard & Poor's (2000).

Los ratings ubicados en la parte superior de esta tabla indican mejor calidad crediticia del emisor o instrumento de deuda. En la medida que se desciende en la tabla, los ratings indican un deterioro de su calidad crediticia. Por ejemplo, para la escala utilizada por S&P, AA+ tiene mejor calificación que AA, y ésta mejor que AA-. Además, los ratings con “grado de inversión” implican una mejor evaluación de la calidad crediticia que los de “grado especulativo”, que en este caso incluyen a los ratings desde AAA hasta BBB- y desde BB+ hasta D, respectivamente. Sólo algunas agencias de rating utilizan etiquetas muy diferentes de las usadas por S&P o Moody's (especialmente Duff & Phelps que utiliza una escala numérica desde el 1 al 17), pero la mayoría se asemeja al tipo de etiquetas mostradas en esta tabla.

El rating puede referirse a un instrumento de deuda en particular o sobre la posición crediticia de la organización en un área o tipo de deuda específica. De esta manera existen calificaciones de deuda de largo y de corto plazo, en moneda local o en moneda extranjera. También hay evaluaciones sobre programas individuales de financiación.

El uso de ratings para dimensionar el riesgo crediticio para un bono es aceptable y de común uso, pero no es muy apropiado para agregarlo en forma simple y lineal. Es decir, cualquier medida de tendencia central de ratings (como la moda) de todos los bonos de una cartera es inadecuada como referencia del riesgo crediticio del portfolio. Sin embargo, el cálculo de la PD basada en las tasas de fallido asociadas a cada clase de rating es ampliamente usada, debido a que hay evidencias de que estas PD son relativamente buenos indicadores de riesgo. Para el cálculo de estas PD con datos de rating es necesario suponer que las tasas de fallido que se observan desde datos históricos se conservarán en el tiempo y son aplicables para el tipo de instrumento de deuda para el cual se desea hacer la medición de riesgo crediticio. Este proceso suele llamarse calibración y consiste en: (a) obtener tasas de fallido históricas para cada clase de rating, (b) ajustar una regresión al conjunto de datos ordenados por cada clase, y (c) luego calcular la posición estimada de cada clase de rating según la regresión elegida.

Además del rating un vasto conjunto de modelos miden el riesgo de crédito basándose en la relación entre la deuda y el patrimonio de las compañías que emiten los instrumentos de deuda. Éstos son conocidos como modelos Estructurales. Merton (1974) propuso el primero de estos modelos, donde plantea que los bonos y las acciones de una compañía pueden ser vistos como derechos contingentes sobre los activos de la empresa. Este tipo de modelos tiene al menos dos importantes ventajas respecto de modelos basados en rating y spread. La primera es la disponibilidad de un subyacente contexto económico para el evento de fallido, y la segunda, es la posibilidad para relacionar la valoración de opciones con tres elementos claves: (i) un comprensible esquema de valoración, (ii) una aleatoriedad no determinística para el evento de fallido, ya que toda la formulación depende del proceso de valoración de los activos, y (iii) usar las analogías de una opción para valorar las demandas de los inversionistas. Otros modelos Estructurales han relajado algunos de los supuestos y han incorporado mejoras en la modelación (Black y Cox, 1976; Geske, 1977; Hull y White, 1995; Longstaff y Schwartz, 1995; Saá-Requejo y Santa Clara, 1997).

En forma paralela al desarrollo de los modelos Estructurales ha surgido otro tipo de modelos en los años noventa: los Modelos de Forma Reducida (*MFR*). Éstos han sido llamados así debido a que los supuestos subyacentes del modelo suponen que los precios de la deuda transada pueden ser derivados *reducidamente* desde los modelos Estructurales (Jarrow y Deventer, 2001). En estos *MFR* el valor de la compañía no es modelado explícitamente y el fallido puede ser inferido desde los spread observados de los bonos. Este tipo de modelos tratan el fallido como un hecho inesperado (puede ocurrir en cualquier momento), en forma independiente de la estructura de capital de la compañía. Los trabajos más importantes son los de Litterman e Iben (1991), Jarrow y Turnbull (1995) y Jarrow et al. (1997).

Otra medida del riesgo crediticio que es usualmente utilizada para los títulos de deuda es el spread o prima por riesgo, determinada de la siguiente manera

$$s_T = R_T - r_T \quad \text{Ecuación 3}$$

donde s_T es la función de prima por riesgo, R_T es el retorno de los bonos cupón cero y r_T es el retorno de los bonos cupón cero libre de riesgo². Esta prima es la rentabilidad adicional que el mercado exige por asumir un nivel de riesgo. En caso de que el spread estuviera determinado exclusivamente por el riesgo de crédito, éste se podría expresar en función del spread, el horizonte temporal y el nivel de recuperación en caso de fallido. Sin embargo, hay evidencia de que el spread no sólo está compuesto

² Los “bonos cupón cero” son bonos que se emiten sin el pago periódico de intereses y se acumulan como primas de amortización al vencimiento del bono y la nominación “libre de riesgo” indica que son títulos sin riesgo de impago, por lo que suelen ser bonos del gobierno.

por el riesgo de crédito, sino que está mezclado con el riesgo de liquidez³, impuestos y otros factores (Deliandedis y Geske, 2001). Además, la relación entre el riesgo de crédito y el riesgo de liquidez en los spread es casi indivisible y desafortunadamente, ambos son bastante difíciles de separar (Bielecki y Rutkowski, 2002). A pesar de esta limitación, el diferencial entre spreads, de un mismo bono, en diferentes momentos del tiempo es usualmente utilizado como un indicador de cambio de la calidad crediticia.

Por otra parte, y para medir el riesgo de crédito en carteras crediticias, también existen modelos patrocinados por compañías del sector financiero que miden el riesgo crediticio de carteras de instrumentos de deuda en términos monetarios. El objetivo final de todos estos modelos es obtener la distribución de pérdidas de la cartera del inversor. Las principales diferencias entre ellos están en cómo modelan el riesgo de fallido y el de cambio de calidad crediticia y si los componentes de medición del riesgo dependen de algún factor externo, como el ciclo económico. Uno de los modelos más aceptados en el mercado es CreditMetrics (Gupton, Finger y Bhatia, 1997). Este modelo parte de la medición de los ratings individuales para bonos. Para la estimación de la distribución de pérdidas, CreditMetrics pone especial énfasis en las pérdidas por impago y en las pérdidas generadas por cambios en calidad crediticia de los activos de la cartera. CreditPortfolioView (Wilson, 1997a, 1997b) utiliza como medición de riesgo de impago individual un modelo en función del estado de la economía⁴. El modelo pone énfasis en la correlación de los impagos de los activos, dependiendo de factores macroeconómicos que indican el estado del ciclo económico. CreditRisk+ (Credit Suisse Financial Products, 1997) es una aproximación actuarial que se aplica también a carteras de bonos, donde la probabilidad de impago de cada activo individual es dicotómica: cae o no en fallido. El número de impagos se determina de forma exógena, para estimar la distribución de pérdidas. Un cuarto modelo es propuesto por KMV (Crosbie, 1999), el que también estima la distribución de pérdidas, pero la medición de riesgo de los activos individuales está basada en el modelo de Merton. Es, por tanto, un modelo Estructural, que depende de la cantidad de deuda y la cotización de las acciones en el mercado.

Estos cuatro modelos se orientan hacia la medición de riesgo de carteras y pueden ser entendidos como los iniciadores de un proceso de integración con otros tipos de riesgos, a pesar de que cada uno de ellos es modelado de distinta manera. CreditRisk+ y CreditMetrics dependen de los ratings externos, aunque CreditRisk+ no modela la dependencia del impago. Sólo KMV y CreditPortfolioView ofrecen una visión integrada, en el sentido de que modela al mismo tiempo la

³ En este documento se entenderá por riesgo de liquidez al riesgo generado cuando una contraparte no puede liquidar en el mercado una obligación por su valor total cuando ésta vence. Los motivos que generan este tipo específico de riesgo son variados, entre los que se cuentan los problemas de ajuste de horarios, canje entre monedas de difícil cambio y tamaño de las operaciones (Peña, 2002).

⁴ En este caso el modelo probit es una aproximación estadística regresiva que sólo considera dos posibles estados en la variable dependiente: fallido y no-fallido.

cartera y los activos. Sin embargo, KMV puede sólo aplicarse a empresas cotizadas en el mercado. Para apreciar la mayor complejidad de estos modelos, la Tabla 2 presenta detalles de los principales modelos construidos para evaluar carteras de bonos.

Tabla 2. Cuadro comparativo de modelos de medición de riesgo crediticio para carteras de bonos

Concepto \ Modelo	Credit Metrics®	CreditRisk+®	CreditPortfolio View®	CreditPortfolio Manager®
Compañía creadora	J.P. Morgan	CSFP	McKinsey	KMV Corp.
Qué es	Mide Distribución de Pérdidas	Mide Distribución de Pérdidas	Mide Distribución de Pérdidas	Mide Distribución de Pérdidas
Información necesaria	Ratings, migraciones, RR, exposición, tasas interés, vencimiento	Ratings, RR, exposición, tasas interés, vencimiento	Ratings, migraciones, RR, exposición, tasas interés, vencimiento, factores macroeconómicos	Exposición, vencimiento, cotización bursátil, base de datos propios u opcionalmente Ratings, spreads y RR
Característica principal	Enfocada a las migraciones de rating	Enfoque actuarial	Incluye modelación macroeconómica	Enfoque Estructural de Activos Contingentes
Opciones de cálculo para la agregación de pérdidas	Simulación	Analítica (a través de bandas)	Simulación	Analítica (pequeña cartera) y simulación
Definición del riesgo de crédito: riesgo por...	Fallido y migración crediticia	Fallido	Fallido y migración crediticia	Fallido y migración crediticia
Probabilidades de migración	Constantes y exógenas desde ratings	No se modelan	Endógenas, basadas en ratings y guiadas por factores económicos	Endógenas derivadas internamente por tasas de fallido y valor de activo
Correlación de los eventos	Por los retornos normales de activos	Con tasa de fallido esperada (asume independencia)	No la estima, ya que está implícita en los factores macroeconómicos	Por los retornos normales de activos
Tasa de recuperación (RR)	Exógena y basada en ratings	Exógena y basada en ratings	Exógena y basada en ratings	Endógena desde datos propios o exógena desde ratings
Relación entre RR y la probabilidad de fallido (PD)	La RR es independiente de la PD	La RR es independiente de la PD	La RR es independiente de la PD	La RR es independiente de la PD
Ventajas importantes	Modela las correlaciones usando el enfoque de activos contingentes Medición completa del riesgo de crédito	Es fácil el cálculo de la PD y las bandas	Condiciona el riesgo al ciclo económico Medición completa del riesgo de crédito Los resultados son dinámicos, ya que dependen del ciclo económico	Modela la PD usando el enfoque de activos contingentes Medición completa del riesgo de crédito Los resultados son dinámicos, ya que dependen de los activos corporativos
Desventajas importantes	No incorpora los efectos de los ciclos económicos Presenta problemas prácticos para estimar las RR por iliquidez del mercado	No incorpora los efectos de los ciclos económicos Es inapropiado su uso para carteras con compras y ventas frecuentes		No incorpora los efectos de los ciclos económicos La estimación de las PD la hace desde bases de datos privadas, sin acceso público

Fuente: Elaboración propia basada en la revisión de la literatura.

Todos estos modelos utilizados para evaluar carteras crediticias miden las distribuciones de pérdidas de la cartera, incorporando la correlación de los eventos de fallido y modelando la RR en forma

independiente de la PD. Asimismo, estos modelos son el primer paso necesario para la medición integrada del riesgo crediticio a otros tipos de riesgos – principalmente el riesgo de mercado y no sólo el riesgo de crédito. La mayoría de estos modelos de cartera utiliza los datos de rating y RR que informan las agencias externas. Este es un dato bastante significativo para esta tesis, ya que pone de manifiesto lo importante que es el rating en el esquema de dimensión del riesgo. Sólo la aproximación que ofrece KMV permite elegir entre el uso de ratings externos, RR externos y datos propios recogidos por esta misma compañía. Cada uno de estos modelos de cartera plantea diferencias y particularidades que les hace especialmente útiles para distintos administradores de carteras de bonos: CreditMetrics destaca por su sencillez y porque mide todo el riesgo de crédito (no sólo la PD); CreditPortfolio Manager destaca por su medición completa del riesgo y el uso robusto de los aportes de Merton (1974), pero tiene la desventaja de utilizar principalmente su base de datos privada; CreditPortfolio View destaca por la medición completa del riesgo condicionada al ciclo económico; y CreditRisk+ sobresale por la facilidad de cálculo, aunque no es apto para la evaluación del riesgo por cambios en la calidad crediticia del deudor.

A modo de resumen de todas las metodologías y modelos de medición de riesgo de crédito, se puede decir que no existe una única aproximación de consenso para su medición, ni siquiera alguna de ellas que incluya a las restantes. Cada una de ellas cumple una finalidad específica. La Tabla 3 ofrece un mapa esquemático de las distintas aproximaciones que se han presentado en este capítulo. En esta tabla se presentan los modelos divididos por banca y bonos. Por ejemplo, la banca puede conceder crédito a personas o bien a empresas; y para dicha concesión se utilizan diferentes enfoques según la finalidad. Sin embargo, para empresas la banca también usa de referencia un indicador generado externamente para medir el riesgo crediticio: el rating de agencias calificadoras de riesgo. Este rating también es emitido para la evaluación individual del riesgo crediticio de bonos. Incluso, el rating de estos instrumentos de deuda también es utilizado como fuente primaria de información para la evaluación de carteras de bonos, con modelos que agregan el riesgo crediticio. Paralelamente a estas aproximaciones, realizadas en gran medida desde la industria financiera, dos corrientes de modelos han emergido desde la academia: los Estructurales y los de Forma Reducida. Para cada uno de estos modelos se presentan en esta Tabla su principal finalidad, la información base que necesitan, y las ventajas y desventajas.

Tabla 3. Resumen de aproximaciones usadas en la medición del riesgo crediticio

		Identificación	Finalidad principal	Información base	Técnica principal	Ventajas	Desventajas
Banca	Personas	Modelos de concesión crediticia	<ul style="list-style-type: none"> Predecir la PD Seleccionar deudores Clasificar ordinalmente s/ calidad crediticia ==> Rating interno 	Datos cuantitativos y cualitativos que caractericen al deudor (principalmente de Estados Financieros)	Estadísticas y de Inteligencia Artificial	<ul style="list-style-type: none"> Métodos sencillos de calcular Medianamente fácil su interpretación 	<ul style="list-style-type: none"> No permiten medir el riesgo de la cartera No miden el riesgo por cambio de calidad crediticia
	Empresas		Rating externo	<ul style="list-style-type: none"> Expresar la calidad crediticia Calificar ordinalmente 	Datos cuantitativos y cualitativos que caractericen al deudor (de la empresa y del mercado)	Opinión de expertos basados en consenso	<ul style="list-style-type: none"> Muy fácil de comprender Ampliamente usados, como medición o como fuente de datos
Bonos	inversión Individual	Estructurales	<ul style="list-style-type: none"> Modelar PD y RR*, y modelar el riesgo por cambio de calidad crediticia 	Precios de mercado (interés y acciones), estructura de capital de la empresa, RR y características del bono	-	<ul style="list-style-type: none"> Usa el enfoque de activos contingentes, lo que es un potente marco conceptual Es dinámico ya que usa datos de mercado 	<ul style="list-style-type: none"> No incluye la modelación del estado de la economía No integra medición total de riesgo por la cartera en forma natural
		de Forma Reducida	<ul style="list-style-type: none"> Modelar PD y RR*, e integrar la medición del riesgo por cambio de calidad crediticia 	Intensidad del fallido, precios de mercado de interés y spread, RR y características del bono	-	<ul style="list-style-type: none"> Parcialmente se han construido modelos que incluyan el estado de la economía y la medición de carteras Es dinámico ya que usa datos de mercado 	<ul style="list-style-type: none"> No integra medición total de riesgo por la cartera en forma natural
	Cartera de inversiones	<ul style="list-style-type: none"> CreditRisk+ CreditMetrics CreditPortfolioView Modelos de KMV 	<ul style="list-style-type: none"> Medir la distribución de pérdidas de la cartera 	Depende del modelo, pero todos aceptan el uso de Ratings, RR y características del bono	Regresiones y simulaciones	<ul style="list-style-type: none"> Evaluación total del riesgo para carteras Es el primer paso para la integración con otros tipos de riesgos 	<ul style="list-style-type: none"> Correlaciones de cartera entre la PD y la Prob.de migración son difíciles de estimar

Fuente: Elaboración propia.

En la Tabla 3 es posible observar que, para cada aproximación al riesgo crediticio, pueden cambiar los objetivos y las técnicas utilizadas, aun cuando la información base sea semejante. Por ejemplo, la información para emitir ratings y la usada por los modelos de concesión crediticia es muy similar, pero la finalidad de ambos difiere sustantivamente. Por ello, la definición de riesgo crediticio en estas dos aproximaciones es diferente: los modelos de concesión crediticia se concentran en el riesgo por fallido mientras que los ratings están concebidos para ayudar a medir la PD y el riesgo por cambio en la calidad crediticia. En la Tabla 3 también aparecen las ventajas y desventajas de los modelos. Por ejemplo, es posible advertir que los modelos de concesión son los más intuitivos y sencillos, mientras que los modelos para medir el riesgo de carteras son más complejos, sobre todo por el cálculo de las correlaciones entre la PD y la probabilidad de cambio de calidad crediticia.

Los modelos que permiten medir el riesgo crediticio de bonos en forma individual – ya sea Estructural o de Forma Reducida – tienen como principal ventaja la utilización de datos de mercado en forma dinámica para el proceso de medición, lo que les proporciona una mayor rapidez (asumiendo que el mercado reconoce rápidamente la calidad crediticia) y flexibilidad. Además, una interesante particularidad de estas aproximaciones es que permiten la inclusión de productos derivados para la medición del riesgo de crédito. Esto cobra una mayor relevancia a raíz de la creciente importancia que toman estas operaciones en los mercados financieros. Por otra parte, estos modelos de medición del riesgo, inicialmente, se concentraban en la cuantificación del riesgo en forma individual; sin embargo, en últimos acercamientos la inclusión sistemática de los efectos de la correlación con el mercado y la economía, y la correlación con otros instrumentos de deuda es cada vez más frecuente. De igual manera, la separación inicial entre modelos Estructurales y de Forma Reducida se difumina cada vez más en la medida que aparecen modelos híbridos que aprovechan ambos enfoques (Ammann, 2001; Duffie y Lando, 2001; Giesecke y Goldberg, 2004).

Con este sucinto resumen de enfoques se ha querido dejar claro al menos tres aspectos:

- 1°. La manera de medir el riesgo de crédito depende del objetivo que se pretende evaluar por quien toma la decisión de conceder los fondos.
- 2°. Hay una clara división en la manera de dimensionar el riesgo crediticio: de una manera individual o en una cartera.
- 3°. Para ambos enfoques, la calificación crediticia emitida por una agencia de rating resulta útil e importante, además de que es ampliamente usada en la práctica financiera.

Por lo tanto, la siguiente sección se concentrará en la medición del riesgo desde la óptica individual, principalmente debido a que es parte del objetivo de esta tesis.

2.3 Medición del riesgo crediticio individual

Los modelos de riesgo de crédito individual bancarios suele enfocarse en la decisión de conceder o no créditos, y a qué precio hacerlo. Los modelos de riesgo de crédito tratan de evaluar el riesgo de crédito individual, y lo hacen comúnmente con técnicas estadísticas o con algunas técnicas de Inteligencia Artificial. En todos los casos el objetivo es una medición directa o indirecta de la probabilidad de impago individual a partir de la información sobre el deudor. A continuación se presentan todos estos modelos, poniendo especial énfasis en la utilización del rating como medida del riesgo crediticio.

2.3.1 El Rating como medida de riesgo crediticio individual

Una forma muy fácil de comprender el nivel del riesgo de crédito que tiene un instrumento de deuda o de un deudor corporativo o institucional en un momento del tiempo, es a través de los ratings de agencias de calificación de riesgo. Hoy, estas agencias son compañías altamente especializadas en la entrega de una opinión formal de la calidad crediticia de compañías o instrumentos de deuda. Dicha opinión se traduce en una calificación (rating), la que a su vez, es ampliamente utilizada tanto para tomar directamente la decisión de inversión y crédito, como para su inclusión en modelos de evaluación de riesgo.

Todas las agencias resaltan que la evaluación es realizada por equipos de expertos financieros y no se trata de un simple conjunto de reglas y procedimientos basados en metodologías cuantitativas. En este proceso de evaluación crediticia es vital la interpretación de la información que hacen expertos. Cuando la empresa a evaluar es quien solicita la calificación, las agencias demandan información a la empresa (a través de entrevistas e informes) y capturan datos desde el mismo mercado y sector industrial. En dicho proceso, las agencias de rating aplican enfoques que obedecen a su particular visión del riesgo crediticio y, por tanto, estas agencias dan diferentes grados de importancia a la información recolectada y la aplican de diferente forma. Por ejemplo, S&P dice concentrar sus esfuerzos en detectar el riesgo que puede tener la compañía en su sector industrial (López, 1996; Standard & Poor's, 2000); mientras que Moody's focaliza sus esfuerzos hacia aspectos fundamentales de la compañía, tales como las características de su oferta y demanda, su competitividad en el mercado o la comparación de la estructura de costos con la competencia (López, 1996; Moody's Investors Service, 1995).

A pesar de estas diferencias entre los procedimientos de cada agencia, los resultados de las tasas de fallido parecen ser similares. Las tasas de fallido por cada nivel de rating de diferentes agencias son relativamente próximas. Treacy y Carey (1998) presentan una comparación entre las tasas de fallidos (a un año) de bonos de compañías estadounidenses con rating de S&P y Moody's. Como se puede observar en la Tabla 4, las tasas promedio de fallido de bonos en cada una de las categorías de rating

no difieren significativamente. En este ejemplo, el 1,17% de los bonos con rating BB de S&P entre 1981 y 1994 incurrieron en fallido, y el 1,42% de los bonos Ba de Moody's lo hizo entre 1970 y 1995.

Tabla 4. Tasa promedio de fallido a un año de bonos con rating

	Moody's		S&P	
	Rating	Tasa anual de fallido, promedio 1970-1995	Rating	Tasa anual de fallido, promedio 1981-1994
Grado de inversión	Aaa	0,00%	AAA	0,00%
	Aa, Aa1, Aa2, Aa3	0,03%	AA+, AA, AA-	0,00%
	A, A1, A2, A3	0,01%	A+, A, A-	0,07%
	Baa, Baa1, Baa2, Baa3	0,13%	BBB+, BBB, BBB-	0,25%
Grado especulativo	Ba, Ba1, Ba2, Ba3	1,42%	BB+, BB, BB-	1,17%
	B, B1, B2, B3	7,62%	B+, B, B-	5,39%
	Caa, Ca, C	n,a,	CCC, CC, C	19,96%
Fallido	D	...	D	...

Fuente: Treacy y Carey (1998, pág. 900)

Con estas series de datos, las agencias de rating también calculan las probabilidades de que los ratings cambien a otra clase en un período determinado de tiempo, lo que se conoce como probabilidad de transición o de migración. Para el cálculo de las probabilidades de transición se utilizan las frecuencias relativas de los promedios históricos de los saltos de rating. Esta probabilidad de transición es muy útil porque se usa como proxy de la probabilidad de cambio de la calidad crediticia del deudor o instrumento de deuda. El período que suele utilizarse para medir la transición es de un año, aunque existen matrices de transición que miden cambios desde 2 años hasta 15 años. En la matriz de transición de la Tabla 5 se exponen los cambios porcentuales a un año de ratings de bonos corporativos que Moody's calculó entre 1920 y 1996. En esta matriz se pueden observar las probabilidades de que cada rating de Moody's migre o no al finalizar un año. Por ejemplo, la probabilidad de que un bono con rating Aa (identificado en la primera columna como Rating inicial) se mantenga al cabo de un año es del 91,62%, mientras que la probabilidad de que su rating descienda a Baa es del 0,7%.

Tabla 5. Matriz de transición: cambios porcentuales de ratings de Moody's de bonos (1920 a 1996)

Rating inicial	Rating a fin de año							
	Aaa	Aa	A	Baa	Ba	B	Caa-C	Default
Aaa	92,18	6,51	1,04	0,25	0,02	0,00	0,00	0,00
Aa	1,29	91,62	6,11	0,70	0,18	0,03	0,00	0,07
A	0,08	2,50	91,36	5,11	0,69	0,11	0,02	0,14
Baa	0,04	0,27	4,22	89,16	5,25	0,68	0,07	0,31
Ba	0,02	0,09	0,44	5,11	87,08	5,57	0,46	1,25
B	0,00	0,04	0,14	0,69	6,52	85,20	3,54	3,87
Caa-C	0,00	0,02	0,04	0,37	1,45	6,00	78,30	13,81

Fuente: Carty (1997, Exhibit 8).

Para construir matrices de transición es necesario el encuentro de dos supuestos básicos: (a) que el comportamiento pasado de la calidad crediticia y del fallido sean el mismo en el futuro y (b) que todos los activos dentro de una clase de rating tengan la misma probabilidad de fallido. Sin embargo, hasta la fecha no existen evidencias de que el primero de estos supuestos no se cumpla. Aun así, las tasas de

fallido a través del tiempo informadas por las agencias de rating no han variado significativamente (Carty, 1997).

Con los datos de fallidos las agencias también construyen probabilidades acumuladas de fallido para distintos años o multi-períodos. En la Tabla 6 se pueden observar las probabilidades de fallido para distintos niveles de rating y con alcance de hasta 10 años.

Tabla 6. Probabilidades acumuladas de fallido a diferentes horizontes anuales (como porcentaje)

Rating	Años									
	1	2	3	4	5	6	7	8	9	10
Aaa	0,00	0,00	0,00	0,04	0,12	0,21	0,31	0,42	0,54	0,67
Aa	0,02	0,04	0,08	0,20	0,31	0,43	0,55	0,67	0,76	0,83
A	0,01	0,05	0,18	0,31	0,45	0,61	0,78	0,96	1,18	1,43
Baa	0,14	0,44	0,83	1,34	1,82	2,33	2,86	3,39	3,97	4,56
Ba	1,27	3,57	6,11	8,65	11,23	13,50	15,32	17,21	19,00	20,76
B	6,16	12,90	18,76	23,50	27,92	31,89	35,55	38,69	41,51	44,57
Investment-Grade	0,05	0,17	0,35	0,59	0,82	1,07	1,34	1,61	1,91	2,21
Speculative-Grade	4,15	8,39	12,19	15,48	18,56	21,26	23,48	25,60	27,54	29,46
All Corporates	1,30	2,61	3,76	4,77	5,67	6,46	7,13	7,76	8,37	8,96

NOTA: Probabilidades basadas en datos entre 1970 y 2000 de Moody's de rating de compañías.

Fuente: Hamilton, Gup-ton y Berthault (2001), Exhibit 41.

Tanto inversionistas y analistas de mercado como algunos modelos (entre ellos CreditMetrics) utilizan esta información proporcionada por las agencias de rating para realizar la medición del riesgo crediticio de una forma sencilla: calificar la posibilidad de que el deudor caiga en fallido o cambie su calidad crediticia a uno o más años (suponiendo que la probabilidad de transición es una adecuada aproximación).

La facilidad para realizar las mediciones es una importante ventaja, ya que permite entender directamente cual es el riesgo asumido y ayuda a tomar la decisión de conceder o no el crédito (o invertir o no en un instrumento de deuda).

Sin embargo, existen algunas limitaciones vinculadas a este sistema de medición de riesgo. Una de ellas se debe a que el rating es una calificación consensuada concedida por un equipo de personas (aunque expertas); y consecuentemente, ésta puede diferir en algún grado de la verdadera calidad crediticia, ya que la interpretación de la información que estas personas hacen es un proceso subjetivo y sometido al error humano. Podría llegar a significar un problema asumir que los cambios de rating son equivalentes a los cambios de calidad de crédito. Pero, debido a que no existe aún una medida indiscutible de la calidad crediticia, se utilizan sustitutos como el rating o el spread.

Segundo, debido a la falta de evaluación oportuna de los cambios de rating, las compañías pueden cambiar considerablemente la calidad del crédito sin que el rating lo haga. Luego, si las migraciones se producen en un momento posterior al cambio de la calidad crediticia, entonces, las matrices de

transición conllevan una pequeña ineficiencia o un desfase temporal respecto de la verdadera calidad crediticia del deudor (Peña, 2002). Aun más, es posible que el mercado haya descontado en el spread dicho cambio mucho antes de que se produzca el salto de rating. Siguiendo a Kealhofer, Kwok y Weng (1998), esto podría ser el motivo de que las probabilidades de migración son bajas (o las de permanecer en el mismo rating, son altas)

Tercero, y siguiendo a Kealhofer et al. (1998), las tasas históricas de impago pueden estar sobrestimadas en forma significativa debido a que los fallidos observados en cada clase de rating son asimétricos a la derecha. “Las tasas de fallido tienden a sobrestimar el riesgo de fallido de empresas con rating de mediana calidad, debido a la presencia de empresas que deberían haber bajado de rating” (Ídem, pág.22). Los errores son mayores en la medida que el bono tiene asignado un rating alto y cuando el horizonte temporal es de corto plazo.

Cuarto, hay evidencias acerca de las diferencias en las tasas de fallido dentro de cada clase de rating. Por ejemplo, “algunos bonos de alta calidad de rating tienen mayores tasas de fallido que otros bonos de baja calidad de rating” (Kealhofer et al., 1998, pág. 4). Los solapamientos más relevantes se producen respecto de ratings que encuentran cercanos en la escala, por ejemplo, bonos tipo BBB que deberían tener la asignación AA, o bien B. Este solapamiento podría producirse por la lentitud en el proceso de revisión y recalificación por parte de las agencias.

Quinto, recientes estudios sugieren que las calificaciones no solicitadas están sesgadas a la baja, en comparación con aquellos ratings solicitados. Utilizando calificaciones no solicitadas de S&P, Poon (2003) muestra que las calificaciones no solicitadas son inferiores a valoraciones solicitadas. Firth y Poon (2005) y Van Roy (2006) también revelan que los ratings no solicitados de Fitch son inferiores a aquellos que si son solicitados. Este hecho induce a retornos anormales para períodos que tienden a bajar los ratings y tienen un mayor impacto en los ratings de grado especulativo que en los de inversión (Byou y Shin, 2012).

Aun más, diferentes eventos han ido mermando la credibilidad de la tarea de las agencias de rating y durante la crisis financiera de 2008 más se ha empañado su reputación. Han tenido fuertes ataques no sólo por otorgar altas calificaciones para productos estructurados con dudosa calidad crediticia, sino también por sostener una buena calificación crediticia a compañías justo antes de que quebraran (como el caso de Lehman Brothers). Además del pobre desempeño en el pronóstico de estas agencias, algunos críticos culpan a las agencias de amplificar efectos procíclicos y aumentar la incertidumbre del mercado no sólo en las calificaciones corporativas sino también en casos de deuda soberana.

A pesar de estas críticas, las calificaciones de estas agencias (sobre todo de las tres grandes) siguen siendo ampliamente utilizadas en la práctica financiera, por muchas empresas y reguladores de gobierno. En EUA esto se debe en parte a las exigencias de la U.S. Securities and Exchange Commission, ya que para determinadas inversiones, el deudor debe contar con un específico nivel de calidad crediticia informada por la agencia de rating. No obstante, dicha hegemonía ha comenzado a balancearse, debido a las presiones públicas y de algunos gobiernos. En EUA y Europa se han tomado medidas para regular las tres principales agencias de calificación y garantizar una mayor transparencia y competitividad. A principios de 2011, la UE creó la Autoridad Europea de Valores y Mercados para regular las actividades de dichas agencias. Sin embargo, estos son sólo pasos iniciales para mejorar la manera en que opera el sistema de calificación crediticia.

Más allá de críticas específicas a la metodología como llegar a los rating, algunos autores (como Bloechlinger, Leippold y Maire, 2012) proponen que cualquiera que a) sea el sistema que se use, éste debe funcionar razonablemente bien en momentos en que existan tensiones en los mercados, b) el sistema que se emplee debe ser transparente, especialmente si se utiliza con fines de regulación, y c) que dichas calificaciones crediticias es preferible que, como son previsiones, sean a un momento del tiempo y no a través de un ciclo.

Con todo lo anterior, los ratings emitidos por las agencias calificadoras juegan un importante papel tanto en la medición del riesgo crediticio como en la práctica financiera. Diferentes modelos auspiciados por agentes evaluadores de riesgo los utilizan como insumo de datos para evaluar el riesgo crediticio. Estos modelos son los que se exponen a continuación.

2.3.2 Aproximaciones para la concesión de créditos bancarios

Este tipo de modelos se ha usado fundamentalmente para la concesión de créditos y la industria bancaria los ha utilizado ampliamente. En esta industria se han llevado a cabo los primeros y principales avances, debido a que una de sus principales funciones corporativas es la de colocar los fondos ahorrados por sus clientes. La finalidad de estos modelos de concesión de crédito bancario es detectar aquellos clientes que caerán en fallido, excluyendo de la definición del riesgo de crédito la pérdida provocada en el valor de los préstamos por los cambios de calidad crediticia del deudor. Lo que se busca con estos modelos es obtener una regla de decisión para establecer si se concede o no el crédito al cliente.

Para formarse un juicio de la calidad crediticia de un deudor, la banca se concentra en tres tipos de datos: la información acerca de la compañía, del mercado donde compite la compañía y de la economía (Andersson, 2001). La banca evalúa este tipo de información, la pondera y concluye las condiciones para otorgar o no el crédito solicitado por el cliente. Siguiendo a Colett y Schell (1992) y

a Krahen y Weber (2001), los factores sobre los cuales se suele concentrar la atención para evaluar la concesión de créditos son los siguientes:

- (a) la relación del cliente con las actividades del banco: en la medida que el historial que tiene el cliente es intachable y la relación cliente-banco es estrecha, mayor será la posibilidad de aprobación del crédito,
- (b) de los factores estratégicos del cliente: en la medida que los fondos solicitados impliquen mayores beneficios y/o menores riesgos, mayor es la posibilidad de aprobación,
- (c) las condiciones financieras y económicas que tenga el cliente (lo que influye directamente en la capacidad de pago de la deuda),
- (d) la calidad del equipo que gestiona las actividades del cliente,
- (e) la exposición del crédito solicitado y la evaluación cuantitativa del riesgo que tendría en la cartera bancaria, y
- (f) las perspectivas de la economía y la industria del cliente.

Para simplificar la comprensión de estos factores se han creado algunas reglas nemotécnicas que se refieren a la evaluación crediticia de una compañía. Una de ellas, denominada el método de las “cinco C”, hace referencia a cinco factores que se deben considerar en esta evaluación (Synkey, 1992; Coyle, 2000; del Águila et al., 2002): *Character* (se refiere a la integridad del solicitante y de su equipo directivo), *Capacity* (es la capacidad de pago expresada a través de los flujos futuros de caja), *Capital* (el patrimonio acumulado a través de la gestión histórica del cliente y como un factor de garantía frente a situaciones imprevistas o adversas), *Collateral* (son las garantías que ofrece el deudor y que son las que reducirán las pérdidas en caso de fallido) y *Conditions* (se refiere a las condiciones que formalizarían el contrato de deuda, tales como el monto del crédito, el tipo de contrato, los plazos y periodicidad, garantías y la tasa de interés). De una manera similar, otro conjunto nemotécnico de reglas que se asemeja mucho al modelo de las 5 C es CAMPARI (Steel, 1994). CAMPARI propone concentrarse en siete factores de riesgo: *Character, Ability, Means, Purpose, Amount, Repayment e Insurance*.

Para la evaluación de la concesión crediticia bancaria se utilizan datos financieros que provienen de los informes contables de las mismas compañías solicitantes (informes de ventas, presupuestos de caja y proyecciones de utilidades), de informes de agencias de rating o de compañías que recopilan información financiera de diverso tipo e información del mercado de capitales. También se utilizan datos no financieros, como artículos de prensa especializada, reportes de brokers e instituciones asesoras especializadas en economía, e informes de agencias que notifican de las actividades de mercados específicos y de las perspectivas industriales. Esta información puede ser cuantitativa (volúmenes, ratios, tendencias) o cualitativa (juicios u opiniones de expertos respecto a las actividades o posición relativa del cliente).

Las primeras investigaciones de predicción de fallidos (Ramser y Foster, 1931; Fitzpatrick, 1932; Durand, 1941) no tenían métodos estadísticos avanzados ni hacían uso de cálculos computacionales para ello. La metodología consistía en comparar los valores de indicadores financieros de compañías fallidas con aquellos de empresas no fallidas. Posteriormente surgieron modelos, alimentados con información cuantitativa, que permitían obtener una medida que orientara a quien toma la decisión de conceder o no un crédito, de una manera sistematizada, rápida y con un nivel determinado de precisión. Una cualidad de este tipo de modelos es que es un sistema objetivo, que entrega una señal discrecional y clara respecto de la concesión crediticia. La eficiencia dependía de la capacidad predictiva del modelo y de la técnica elegida. En 1966 el estudio Beaver presentó una aproximación univariante y, en 1968, Altman extendió este análisis con un enfoque multivariante. A partir de entonces, ha evolucionado un cuerpo impresionante de investigación teórica y empírica acerca de este tema, distinguiéndose dos principales aproximaciones: la primera ha sido la búsqueda empírica de variables o factores, especialmente, ratios financieras que conduzcan a menores tasas del error en la predicción; y el segundo acercamiento se ha concentrado en la búsqueda de métodos Estadísticos y de Inteligencia Artificial (IA) que también mejoren la exactitud de la predicción. La mayoría de los estudios que predicen o explican los fallidos corporativos tienen un acercamiento empírico. Es decir, estos estudios apuntan a la exactitud de la predicción mejorada por la selección apropiada de variables financieras para el análisis. Hay algunos esfuerzos para crear construcciones teóricas para la predicción de fracaso, pero ninguna es generalmente aceptada como una base teórica para la selección de variables. De ahí que la selección de variables usualmente se base en características empíricas. Esto también ha llevado a que las investigaciones seleccionen el método estadístico de una manera empírica.

En general, las variables usadas para construir los modelos predictivos expresan la posición financiera, patrimonial y dimensionan la gestión de la compañía. Particularmente, estas variables intentan capturar información acerca de la liquidez, la rentabilidad, del endeudamiento y nivel de actividad. En la Tabla 7 se presenta una clasificación de los principales tipos de variables utilizados en la literatura financiera para predecir la quiebra de empresas. En este resumen se exponen sólo los trabajos iniciales de esta corriente – los más citados – y aquellos más recientes. Se han clasificado de acuerdo con el tipo de variable (tamaño, actividad, financiación, liquidez, rentabilidad, características propias de la compañía y aquellas que utilizan un sistema de variables agrupadas) y se presentan algunos ejemplos para cada una de estas tipologías, junto a sus referencias. Además, en la Tabla A 1 del Anexo A se presenta un listado de estas variables y la referencia donde han aparecido.

Tabla 7. Variables de algunos modelos con fines de predicción de quiebra en empresas

Tipo de variable	Ejemplos del tipo de variable	Referencias
tamaño	Log of total assets ; total assets	Flagg y Giroux (1991), Frydman, Altman y Kao (1985)
actividad	Accounts receivable / sales; Cash / sales; Inventory / sales; Sales / total assets	Beaver (1966), Altman (1968), Frydman, Altman y Kao (1985), Edmister (1972), Theodossiou (1993), Zavgren (1985), Becchetti y Sierra (2003)
financiación	Cash flow / total debt; Fixed assets / total assets; Long-term debt / total assets; Total debt / total capital	Beaver (1966), Altman (1968), Frydman, Altman y Kao (1985), Becchetti y Sierra (2003)
liquidez	Cash / total assets ; Cash / current liabilities; Current assets / sales; Net working capital / sales; Net working capital/ current liabilities; receivables + inventory / total assets	Beaver (1966), Edmister (1972), Zavgren (1985), Casey y Bartczak (1985), Frydman, Altman y Kao (1985), Flagg y Giroux (1991), Theodossiou (1993), Spathis (2003), Becchetti y Sierra (2003)
rentabilidad	Net income / total assets; EBIT / total assets; Operating income / total assets; EBIT / total debt; Retained earnings / total assets	Beaver (1966), Altman (1968), Kaplan y Urwitz (1979), Zavgren (1985), Casey y Bartczak (1985), Frydman, Altman y Kao (1985), Flagg y Giroux (1991), Theodossiou (1993), Becchetti y Sierra
características	Qualified opinion (going concern); Firm sales/industry sales; Age; Tiene o no litigio en el año; pérdidas del a compañía durante el año;	Flagg y Giroux (1991), Spathis (2003), Becchetti y Sierra (2003)
sistema de variables	Strength and proximity of competitors Fallos en la gestión, errores comerciales y síntomas de quiebra basados en M variables cualitativas con p% de relevancia; variable multiescala: z--score de Altman para predecir quiebra	Argenti (1977), Spathis (2003)

Fuente: Elaboración propia

El argumento teórico más usado para seleccionar las variables se basa en que se debe capturar la información acerca de la capacidad de generación de flujos de efectivo y el mantenimiento de un equilibrio financiero corporativo. Esta línea teórica supone que los fondos disponibles o líquidos para cancelar las deudas – especialmente las de corto plazo – son obtenidos desde las operaciones normales que dan origen a ventas o servicios prestados y desde los proveedores estructurales de financiación (deuda y capital). Para evitar una situación financiera crítica (y eventualmente el fallido), una compañía debería controlar los flujos de pagos e ingresos de efectivo para sobrevivir a períodos de adversidad financiera, provocados por situaciones inesperadas o por condiciones cíclicas: descenso de las ventas y/o de los cobranzas, cambios en los tipos de interés, recesiones, incremento de la competencia, entre otras (Ward, 1994). Por lo tanto, los aspectos importantes a estudiar en la empresa evaluada son la disponibilidad de fondos líquidos, la estructura de financiación y las operaciones que generan los recursos.

También se han utilizado variables de flujos operacionales de efectivo, bajo la premisa de que las compañías no pueden sobrevivir sin la generación de sus operaciones normales; y, por lo tanto, deberían ser las variables más relevantes en la construcción del modelo. Esta propuesta no invalida la corriente teórica basada en los flujos de efectivo y el control del equilibrio financiero, sino que cambia el foco de atención, suponiendo que el fallido se provocaría desde la inadecuada gestión de pagos y cobros. Algunos trabajos en este tipo de corriente teórica son Gentry, Newbold y Withford (1985) y Casey y Bartczak (1984).

Igualmente se han propuesto otro tipo de datos que rescatarían información general y específica acerca de la compañía y que podría ser útil para la predicción del fallido o la concesión de créditos. Un grupo de variables no contables es iniciado por Argenti (1977)⁵, quien incluye en su modelo una puntuación basada en potenciales defectos de la gestión de los negocios y de la estructura financiera. A este estudio le han seguido otros acerca de factores latentes que se relacionan con el default de la compañía: calificaciones de las firmas auditoras, litigios de las empresas, políticas de administración y variabilidad de los precios de bolsa (Keasey y Watson, 1987; Flagg y Giroux, 1991; Wilson, Chong y Peel, 1995; Spathis, 2003). Otro tipo de variables no financieras se refiere a mediciones sobre la concentración y poder negociador de sus clientes o la competitividad de la industria en que se encuentra la compañía evaluada (Becchetti y Sierra, 2003; Everett y Watson, 1998). Estos factores intentan medir el grado relativo de eficiencia de la compañía respecto a su industria o su posición relativa. El supuesto implícito es que en la medida que la compañía se aleje más de las mejores prácticas (las de su mercado), mayor es la probabilidad de ocurrencia del fallido de la empresa. Para lograr este acercamiento es preciso asumir la validez de un modelo que permita definir una frontera eficiente o cual es el foco de eficiencia en la industria. (Maksimovic y Phillips, 1998; Battese y Coelli, 1995).

Desde estos modelos, además de la regla de decisión “acepta o rechaza” la solicitud de un crédito, cabe la posibilidad de obtener más información. El output del modelo dependerá de su objetivo y de la técnica elegida. No obstante, en la mayoría de los modelos usados es posible obtener (1) la probabilidad de fallido, (2) una clasificación de los deudores según su riesgo crediticio (como un rating) y/o (3) un puntaje que permita observar una proxy de la calidad crediticia del deudor. Atendiendo al objetivo de este tipo de modelos, pueden ser clasificados de la siguiente manera:

- i) Modelos que estiman un puntaje de corte y que sirve para discernir entre la concesión o no del préstamo.
- ii) Modelos que estiman la probabilidad de fallido. Sobre esta estimación se puede elegir el nivel de aceptación o rechazo de los créditos a conceder.
- iii) Modelos que clasifican a los clientes bancarios en grupos o clases de deudores, según su calidad crediticia. Esta aproximación es similar a la asignación de rating que realizan las agencias calificadoras, con diferencias en las metodologías para estimar la pertenencia de cada cliente a un grupo o clase.

2.3.2.1 Métodos de puntaje de corte

Los modelos basados en puntajes o estadísticos de corte, a los que es habitual llamar métodos de scoring, son metodologías ampliamente utilizadas en la práctica comercial y bancaria, que sirven para

⁵ El autor de esta tesis no ha tenido acceso directo al trabajo de Argenti (1977) y la información de esta investigación aparece en Collett y Schell (1992) páginas 196 y 197.

discernir entre los clientes a los cuales se les otorga o no el crédito. En este tipo de modelos se asume que existen factores relevantes de riesgo que sirven para distinguir las características de los deudores – a través de ratios financieras o variables del sector industrial. Estos factores son incluidos en un vector $x = (x_1, x_2, \dots, x_m)$ de m variables aleatorias, las que son dadas y conocidas en el modelo de forma exógena. Estos factores sirven para predecir la quiebra mediante el vector $y = (y_1, y_2, \dots, y_j)$ de j tipos de casos. El output del modelo es un puntaje o score que sirve para predecir el fallido. La relación entre los factores y la variable que modela el fallido suele estar determinada por

$$y = \alpha + x'\beta + \varepsilon, \quad \text{Ecuación 4}$$

donde $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_i)$ es el término de error aleatorio de i casos observados, tal que $E(\varepsilon) = 0$. Tanto los factores explicativos como las relaciones que los vinculan con el fallido varían según los supuestos y la metodología empleada. En todos ellos el procedimiento permite obtener un predictor numérico que puede ser utilizado como un puntaje o scoring, según el cual se discrimina o determina la concesión del préstamo. Parte de estos métodos de estimación se basan en estadística inferencial, por lo que es posible, además, obtener la estimación de la probabilidad de fallido. Inclusive, si el output de este modelo se puede relacionar con la calidad crediticia de las compañías, entonces el score o puntaje puede ser entendido como una proxy de dicha calidad. Por ejemplo, en Altman y Saunders (1998), Saunders (1999) y Altman (2002) se expone la directa relación entre el puntaje obtenido con modelos de scoring, la puntuación EDF (por las siglas de *Expected Default Frequency*) de KMV y los ratings de una agencia externa. La Tabla 8 muestra la directa relación existente entre los ratings de bonos en 1994 y los puntajes medios de sus compañías.

Tabla 8. Equivalencia entre ratings con grados de inversión y especulativo y su score medio

Rating g.inversión	Z-score medio	Rating g.especulativo	Z-score medio
AAA	8,15	BB+	8,15
AA+	7,6	BB	7,6
AA	7,3	BB-	7,3
AA	7	CCC+	7
AA-	6,85	CCC	6,85
A	6,65	CCC	6,65
A-	6,4		
BBB+	6,25		
BBB	5,85		
BBB-	5,65		

Nota: Equivalencia entre ratings de bonos de 750 compañías de EUA (en 1994) y su score medio
Fuente: Elaboración propia basada en Altman y Saunders (1998), Tabla 4.

La primera investigación bajo esta aproximación de scoring fue la de Durand (1941), para discriminar créditos. La utilización de análisis discriminante como método de scoring ayudó a que esta aproximación fuese difundida ampliamente. Uno de los primeros trabajos que ayudó a popularizar este tipo de modelos fue el de Altman (1968), que luego divulgó el modelo con el nombre de Z-score. Poco tiempo después, otro estudio utilizaba un sistema de ponderación lineal para separar empresas en fallido. Se trataba del modelo de Argenti (1977). Muchos otros trabajos han continuado la aplicación de técnicas estadísticas que buscan delimitar grupos de empresas en función de un puntaje de corte (Blum, 1974; Coats y Fan, 1992).

Otro conjunto de técnicas utilizadas para la concesión de créditos que ha tenido éxito son los sistemas automáticos o máquinas de IA. Estas técnicas permiten construir complejas relaciones entre los datos (reconociendo inclusive relaciones no-lineales entre las variables), asumiendo que subyacentemente las variables de entrada permitirán encontrar el punto de corte. Entre estas técnicas, las redes neuronales artificiales⁶ han tenido un fuerte desarrollo en las últimas dos décadas. Otra aproximación de IA que puede ser aplicada para la obtención de un score que permita la distinción entre los clientes bancarios son los *árboles de decisión*⁷, donde la salida en cada proceso decisión es un score que permite clasificar al sujeto evaluado para cada variable del modelo. Todas estas aproximaciones Estadísticas y de IA permiten diferentes grados de precisión, y no existe un único estudio comparativo de todas estas metodologías. Las comparaciones entre ellas son parciales y no utilizan los mismos datos de entrada y, lo que es más diferenciador aún, no se usan las mismas variables explicativas. La Tabla 9 muestra tres modelos, a modo de ejemplo, usados por diferentes autores. En el caso de Altman (1968) las variables predictoras son sólo seis y la técnica utilizada es análisis discriminante.

Tabla 9. Ejemplos de modelos de puntaje de corte para predicción de quiebra.

Referencia	Variables incluidas en el modelo		Técnicas usadas
Altman 1968	Working Capital / Total Assets Earning before Income Tax / Total Assets Sales / Total Assets	Retained Earnings / Total Assets N.W. (book value) / Total liabilities	Análisis Discriminante
Ohlson 1980	Log (Total Assets / GDP index) Working Capital / Total Assets Total Liabilities / Total Assets Funds by Operations / Total Liabilities Change in Net Income Level	Total Liabilities / Total Assets Current Liabilities / Current Assets Net Income / Total Assets Net Income / Total Assets Negative Income for last 2 years	Análisis Discriminante
Serrano 1997	Current Assets / Total Assets Liquid Assets / Total Assets Current Assets / Loans Reserve / Loans Net Income / Total Assets	Net Income / Total Equity Capital Net Income / Loans Cost of Sales / Sales Cash Flow / Loans	Análisis Discriminante, Regresión Logística y Red Neuronal

Fuente: elaboración propia

El número de investigaciones de scoring crediticio es muy numeroso. En la literatura financiera suele citarse como pioneros los trabajos de Beaver (1966) y Altman (1968), aunque este último es decididamente una de las citas más famosas. Muchos otros han continuado desarrollando esta corriente científica y práctica (Frydman, Altman y Kao, 1985; Edminster, 1972; Theodossiou, 1993; Zavgren, 1985; Becchetti y Sierra, 2003). En esta tesis no se analizarán estos modelos, y sólo es importante mencionar que la heterogeneidad de variables, técnicas y tasas de acierto es bastante amplia. El nivel de acierto suele estar entre el 65% y el 90%, y depende de la base de datos utilizada, los supuestos implícitos y la técnica elegida para realizar la predicción. Las mayores tasas de acierto se logran cuando los datos son de compañías con sectores industriales bastante homogéneos y cuando se utilizan datos de las compañías por más de un período. Por ejemplo, Dhumale (1998) compara los niveles de

⁶ Estas redes neuronales son Sistemas de Aprendizaje Automático interconectados con enlaces, que calculan una función lógica para autoaprender de los procesos subyacentes en los datos de entrenamiento. Ver capítulo 3.

⁷ Los árboles de decisión son Sistemas de Aprendizaje Automático que dividen el espacio del problema en subconjuntos, hasta que estén lo suficientemente definidos en función de las clases predefinidas. Ver capítulo 3.

precisión total (compañías fallidas y no fallidas clasificadas correctamente) con datos de una muestra de 93 compañías textiles de India, entre el período 1964 a 1973. Los resultados obtenidos para los modelos con análisis discriminante van del 77% al 88,5%, y los compara con los obtenidos con regresiones logísticas o logit (del 88.5% al 92.5% de acierto) y probit⁸ (del 65.5% al 75% de acierto). Platt y Platt (1990) comparan los resultados obtenidos de una muestra de 152 compañías de EUA (de distintos sectores industriales) durante el período 1972-1986. De su comparación se obtiene que la precisión se situara entre el 79% y el 95% para modelos que usan análisis discriminante, entre el 76% y el 96% para las predicciones con probit y entre el 79% y el 84% para modelos logit. Consecuentemente, los modelos con mejor desempeño, para esta muestra, fueron los probit. Cabe destacar que, si bien las técnicas de probit y logit tienen como output una probabilidad de ocurrencia, ésta puede ser utilizada como un score en la medida que sirva para discriminar los grupos de la muestra.

Aunque la mayor parte de las investigaciones se refieren al contexto estadounidense, en la última década del s.XX se ha incrementado el estudio de la evaluación crediticia de compañías de otros países. Sung, Chang y Lee (1999) compara los resultados basados en una muestra de 168 compañías coreanas que se incluyen en el Korea Stock Exchange entre 1990 y 1998, separando los períodos de crisis económica de aquellos normales. En ambos tipos de períodos una técnica de árbol de decisión fue mejor predictor de la quiebra de compañías coreanas que el análisis discriminante. En crisis, la precisión lograda con el árbol de decisión fue del 81% y con el análisis discriminante fue del 73.8%. En períodos económicos normales, la precisión lograda fue del 83.3% para el árbol de decisión y 82.1% con el análisis discriminante.

Una propuesta complementaria a este enfoque sugiere analizar el score de las compañías a través del tiempo. Taffler (1983) manifiesta que es más interesante analizar el historial de puntajes de una compañía que usar el mismo score para calcular la probabilidad de fallido. Por ello, este investigador planteó el uso de un índice de riesgo basado en Z-score (llamándolo índice PAS), que refleja el percentil en el que el Z-score de una empresa se encuentra respecto de todas las restantes compañías para un año en particular.

Finalmente, uno de los modelos que incorpora aspectos estructurales de la compañía e información del mercado es fomentado por KMV: el modelo se llama RiskCalc. Este tipo de modelos utiliza la EDF para predecir el fallido. Sin embargo, no existen muchos estudios que permitan la comparación de los estimadores. Uno de los motivos es que los valores de la EDF son de propiedad exclusiva de KMV. Dwyer, Kocagil y Stein (2004) proponen una comparación entre dos modelos de KMV (EDF RiskCalc

⁸ Logit y probit son regresiones que establecen relaciones de dependencia entre las variables explicativas y la variable dependiente. Estas técnicas son explicadas en el siguiente capítulo.

v3.1 y RiskCalc 1.0) y el modelo Z-score de Altman, Haldeman y Narayanan (1977). La Tabla 10 expone dicha comparación, donde se puede observar que el poder predictivo durante los años 1997 y 2000 bajó considerablemente (mismo período en que los fallidos se incrementaron notablemente), pero de estos tres modelos EDF Risk Calc v3.1 siempre tuvieron tasas más altas de precisión en la predicción del fallido a un año de plazo. También se puede observar que con los métodos de predicción las tasas de acierto aumentaron considerablemente en 2001, lo que puede estar vinculado con el proceso económico que afectó a las empresas en dicho año y que hizo bajar significativamente la tasa de fallidos.

Tabla 10. Tasas de acierto de los fallidos en el tiempo (en %)

Año	EDF RiskCalc			Porcentaje de fallidos
	v3.1	RiskCalc v1.0	Z-score	
1993	68,2	64,5	59,4	1,2
1994	57,4	55,4	52,5	3,3
1995	56,6	53,0	44,6	5,6
1996	60,5	60,1	53,0	7,1
1997	47,7	44,2	36,3	11,3
1998	38,9	35,0	28,3	20,8
1999	44,6	39,6	33,5	23,6
2000	49,0	43,6	36,0	19,8
2001	71,9	66,5	55,1	7,2
				100,0

Fuente: Dwyer et al. (2004), Tabla 7.

2.3.2.2 Modelos bancarios que estiman la probabilidad de fallido

La estimación de la probabilidad de fallido es tan importante para la decisión de conceder o no el crédito, que gran parte de los usuarios de las aproximaciones de scoring intenta obtener dicha probabilidad. La mayoría de las técnicas estadísticas y de IA usadas para la concesión crediticia arrojan la probabilidad de ocurrencia de que la compañía pertenezca a un grupo o a otro. Por lo tanto, en la medida que la variable y describa el suceso de fallido o de no-fallido, la probabilidad de ocurrencia representa la PD. También es cierto que gran parte de modelos que se usan para estimar la PD, también permiten interpretar el output como un punto de corte. Por ejemplo, en logit suele fijarse 0,5 (o 50% de probabilidad) como el punto de corte para separar dos grupos. Particularmente, los modelos logit, probit y de probabilidad lineal tienen como output la probabilidad de ocurrencia. En otras palabras, la caracterización de los modelos de scoring se aplica perfectamente a los modelos que estiman la probabilidad de fallido (ver Ecuación 4), con la salvedad que el output es la probabilidad de fallido.

Los primeros trabajos para la predicción de fallidos que utilizaron este tipo de técnicas fueron Ewert (1969), Edelstein (1975), Martin (1977), Ohlson (1980). A estas investigaciones han seguido muchos otros trabajos (Hammer, 1983; Fletcher y Goss, 1993; Baesens, Van Gestel, Viaene, Stepanova, Suykens y Vanthienen, 2003) y en las últimas décadas se ha intensificado el uso comparativo con otras

técnicas predictivas, sobre todo con técnicas de IA. Por ejemplo, Wilson et al. (1995) utilizan una muestra de 112 compañías inglesas que cotizan en bolsa durante 1972 a 1979 para realizar una comparación entre técnicas logit y redes neuronales. En este caso, las predicciones correctas logradas con logit y redes neuronales dejan en evidencia que esta última modelación fue en promedio un 15.4% más eficiente que logit.

Por otra parte, una comparación entre modelos determinísticos basados en ratios contables y un modelo basado en la teoría de opciones propuesta por Merton (1974), es presentada por Hillegeist, Keating, Cram y Lundstedt (2004). En esta comparación se han usado los trabajos de Altman (1968) y Ohlson (1980), mientras que el segundo tipo de modelo es propuesto por los autores de dicha investigación. De la comparación entre estos modelos, Hillegeist et al. (2004) concluyen que el modelo basado en la teoría de opciones (en adelante modelo BSM) provee más información acerca de la probabilidad de quiebra que los modelos de Altman y Ohlson para el conjunto de datos utilizados. En la muestra de 78.100 compañías norteamericanas, durante 1980-2000, la comparación de un estimador del grado de ajuste, el modelo BSM es superior en un 71% y 33% a los estimadores de Altman y Ohlson, respectivamente. Los autores argumentan que la incorporación de la volatilidad de los activos bursátiles es un importante componente para explicar el mejor desempeño en los estimadores de la probabilidad de quiebra en la muestra.

2.3.2.3 Modelos que clasifican a los deudores bancarios

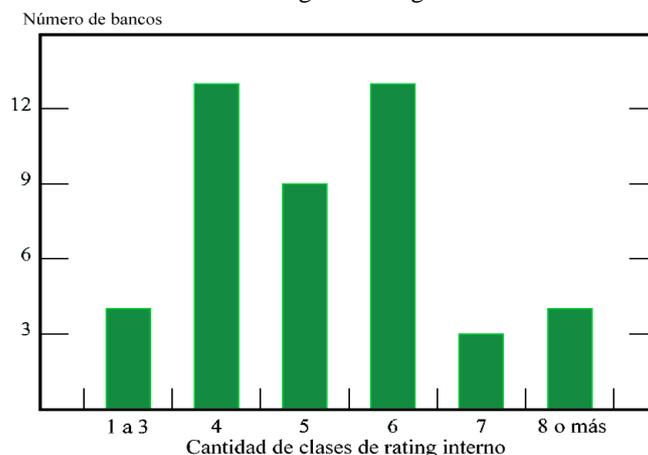
Para la concesión de créditos, las instituciones crediticias también pueden clasificar a sus potenciales deudores en grupos jerarquizados y ayudar a conformar subcarteras con deudores de similar calidad crediticia. Intuitivamente, la agrupación más básica es la división entre “buenos pagadores” versus “malos pagadores”. Pero la división más utilizada en la literatura financiera de la variable dependiente y es entre “fallido” y “no-fallido”. A pesar de ello, actualmente la banca agrupa a sus clientes en más clases de riesgo. Siguiendo a English y Nelson (1998), el 85% de los bancos de EUA ha calificado en alguna escala de riesgo a sus clientes o préstamos (muestra tomada desde 1977 a 1995 a 281 bancos de distintos tamaños) y en 1995 el 95% de los nuevos préstamos tiene una calificación. En adelante se utilizarán indistintamente los términos ranking bancario o rating interno para distinguir esta calificación de las emitidas por las agencias de rating. Estos ranking bancarios son utilizados como medida de riesgo crediticio en el proceso de concesión de créditos, en la medición de reservas por pérdidas de préstamos y en los informes de gestión bancaria. Esto permite la misma interpretación intuitiva de los ratings emitidos por agencias externas (como Moody's o S&P). A pesar de estas similitudes existen tres importantes diferencias:

- i) Los ratings internos no son públicos, a diferencia de los ratings externos. Los ratings internos son asignados por personal bancario y no son revelados a personas ajenas a la institución

bancaria, lo que causa una seria complicación para compararlos y diferenciar las metodologías y resultados de ambos tipos de organizaciones.

- ii) El número de clases de las calificaciones bancarias es menor que la otorgada por agencias externas. Por lo general, los bancos no utilizan más de 6 o 7 clases para tipificar los ratings internos, mientras que las agencias suelen tener unas 30 clases de rating. Según Treacy y Carey (1998), la mayoría de los bancos en EUA (casi el 80%) utilizan entre 4 a 6 clases de ratings internos para calificar sus colocaciones y clientes. La Figura 3 expone como se distribuyen en 1997 los 50 principales bancos estadounidenses clasificados por la cantidad de clases de rating interno. La mayor granularidad de los ratings externo puede ser más costoso el proceso de calificación, ya que requiere mayor trabajo para distinguir más finamente entre los grados de riesgo.
- iii) La finalidad última del banco es diferente a la de la agencia debido a su actividad comercial. Esto incide en la cantidad de recursos destinados a la evaluación. Es decir, la banca utiliza el rating interno para su evaluación crediticia interna y no cobra por ello; en cambio, para las agencias externas los ratings son un activo intangible y realizable, donde la correcta evaluación influye en la credibilidad y reputación que se tiene de la misma agencia. Por lo tanto, la banca suele destinar muchos menos recursos a la verificación constante de los ratings que la agencia externa. La falta de actualización del ranking bancario es una debilidad frente a los ratings externos.

Figura 3. Distribución de los 50 bancos más grandes según el número de clases de rating interno



Fuente: Treacy y Carey (1998), figura 1.

Ong (1999) destaca que es deseable que el sistema de ratings cuente con la mayor granularidad posible. Krahnén y Weber (2001), además de apoyar el diseño de sistemas con el mayor número de clases de rating posibles, plantean otros 13 requisitos que debería tener un buen sistema de rating. Una de las consecuencias de que el número de clases de ratings internos sea menor que las generadas por agencias externas es que al intentar establecer una equivalencia entre ambas escalas, distintas calificaciones de riesgo de las agencias quedan asignadas a una única clase bancaria. Con esto se pierde mucha información respecto del riesgo crediticio y da origen a una mayor imprecisión de la

probabilidad de fallido (Tracey y Carey, 1998). De acuerdo con estos autores estas diferencias aumentan debido a que no se toma en cuenta que los sistemas de las agencias evalúan el riesgo de crédito a través de un ciclo (en forma permanente) mientras que la banca lo hace en un único momento del tiempo.

A pesar de estos inconvenientes, Ong (1999) afirma que este proceso de proyección de equivalencias entre ambos tipos de ratings es conveniente para la banca, debido a que las agencias proveen de información a disposición pública acerca de los fallidos, basada en su propia base de datos histórica. Para establecer esta equivalencia es necesario contar con la precaución de conocer las limitaciones que tiene el sistema de rating de cada banco (características de sus clientes, límites y clases de riesgo preestablecidas por el sistema, periodicidad de la revisión, entre otras).

Los intentos por aplicar modelos de clasificación de deudores de acuerdo a su calidad crediticia utilizan similar metodología de scoring crediticio y de estimación de la probabilidad de fallido (ver Ecuación 4). Las m variables elegidas, en el vector x , para cada modelo intentan capturar la información de la calidad crediticia que es relacionada con el vector y de ratings internos. El output necesario de cualquier modelo clasificador debe entregar la clase predicha del deudor, ya sea a través de (a) un puntaje que permita la división o (b) de un identificador que señale la clase esperada del deudor. Siguiendo a Mählmann (2004), el primero de estos métodos, un score divide toda la amplitud de valores posibles del estimador, obteniendo un número de subintervalos. Estos pueden o no ser simétricos y dependerá de la técnica utilizada. Por lo tanto, es posible usar técnicas como el análisis discriminante, logit, probit y el modelo de probabilidad lineal (todas se analizan en el siguiente capítulo). Ejemplos de este enfoque son las aplicaciones en Baetge, Muss y Niehaus (1988), Blochwitz y Eigermann (1999) y Carey y Hrycay (2001). Baetge et al. (1988) construyen intervalos simétricos alrededor de un estadístico de corte basado en análisis discriminante lineal, mientras que Blochwitz y Eigermann (1999) utilizan probabilidades de fallido estimadas con análisis discriminante. Carey y Hrycay (2001) construyen clases de rating basados en un estimador de máxima verosimilitud condicional de la probabilidad de fallido, basado en tasas de fallido de las clases de rating de Moody's.

Un segundo conjunto de metodologías opta por clasificar la totalidad de los datos basándose en técnicas estadísticas o de IA, sin tomar en cuenta el scoring obtenido. Es decir, la segmentación de clientes o préstamos se realiza en forma directa. Bajo este conjunto de metodologías, cabe incluir a las redes neuronales, a los árboles de decisión y a *métodos basados en vecindad*⁹. Aunque no existe consenso de qué tipo de técnicas es la más apropiada para la clasificación directa, las de IA han aplicado relativamente con éxito las clasificaciones de deudores. Wilson et al. (1995) comparan las

⁹ Los métodos basados en vecindad son Sistemas de Aprendizaje Automático que resuelven problemas a partir de información extraída de un conjunto de ejemplos ya existentes. Revisar el siguiente capítulo.

predicciones de un modelo logit (entre 86.1% hasta el 95% de aciertos) y una red neuronal (entre el 94.4% y el 98.7% de aciertos).

Por último, en la comparación de técnicas utilizadas hay un aspecto que debe observarse con detenimiento: el número de clases sobre las cuales se hace la división del espectro de riesgo crediticio determina el nivel de aciertos en la predicción. La mayoría de las técnicas aumenta el porcentaje de acierto en la medida que tiene menos clases en las cuales clasificar a los deudores. Por lo tanto, en caso de hacer comparaciones siempre es conveniente tener en cuenta las consecuencias que lleva comparar técnicas con diferentes números de clases.

A modo de resumen, la banca se ha concentrado históricamente en dos tareas (i) la medición de la PD para conocer el potencial riesgo en que está incurriendo y (ii) aplicar metodologías que le permitan clasificar a sus clientes-deudores. Con estas dos tareas, la banca selecciona a quién concede crédito y el monto o exposición que le es conveniente otorgar. En esta línea de investigación, la literatura financiera se ha concentrado en modelos que intentan (a) predecir la PD, (b) ayudar a la selección de deudores y/o (c) clasificar ordinalmente al deudor de acuerdo con su calidad crediticia. Basándose en esta separación, la Tabla 11 presenta un resumen de estos modelos ampliamente usados para la concesión crediticia.

Tabla 11. Cuadro comparativo de modelos de concesión de crédito.

	Puntaje de corte	Estimación de la probabilidad de	Clasificación grupal
Objetivo principal	estimar score para jerarquizar	estimar probabilidad de fallido	clasificar
Definición del riesgo de crédito	riesgo de fallido	riesgo de fallido	riesgo de fallido
Objeto de estudio	compañías o personas	compañías o personas	compañías o personas
Ingreso de datos	cualitativos y/o cuantitativos	cualitativos y/o cuantitativos	cualitativos y/o cuantitativos
Tipo de técnicas Estadísticas y de Inteligencia Artificial (IA)	Tanto Estadísticas como de IA, pudiendo ser predictivas o clasificatorias	Principalmente estadísticas y predictivas, como el Análisis Discriminante o las regresiones	Las de IA son muy útiles, especialmente las clasificatorias.
Desventajas desde la perspectiva financiera	La estimación de la probabilidad es indirecta	complejidad en modelación	Complejidad de cálculo
Ventajas desde la perspectiva financiera	facilidad de implementación	estimación directa de la probabilidad	facilidad de implementación y comprensión

Fuente: elaboración propia

En general, los modelos usados para la concesión de crédito son sencillos y fáciles de interpretar, pero no incorporan la medición del riesgo por cambio en la calidad crediticia y no permiten medir el riesgo de la cartera de deuda. Los modelos se basan en técnicas estadísticas o de IA para ayudar a resolver las tareas de concesión crediticia. No obstante, no existe una técnica que sea la más apropiada para todos

los modelos, ya que depende del objetivo del analista o acreedor (determinar un score, la PD o la clasificación) qué tipo de técnica convendría utilizar. Sobre la elección de las técnicas y su significado trata el siguiente capítulo.

De estos tres tipos de enfoques usados por la banca para conceder créditos, los modelos que permiten la clasificación de los deudores según su grado de riesgo, presentan un nuevo e importante impulso debido al incentivo que Basilea II pone para el uso de ratings internos. Para ello, Basilea II plantea que el capital bancario debe depender del riesgo crediticio de su cartera, apoyado en medidas internas, estándares y que incorporen el cambio de la calidad crediticia del deudor en el tiempo. En otras palabras, Basilea II propone el uso de ratings internos con modelos que se asemejen a los que usan los administradores de cartera de bonos (como CreditMetrics).

2.3.3 Dificultades de los modelos de concesión de crédito

En la literatura financiera es posible advertir una serie de críticas referidas a los modelos que ayudan a la concesión de crédito. Estas dificultades pueden ser inherentes a la técnica de estimación, o bien, pueden ser eminentemente financieras. Las primeras son tratadas en el siguiente capítulo, ya que ahí se abordan diferentes técnicas predictivas y clasificatorias. En cambio, las críticas cuyo argumento es eminentemente financiero son tratadas a continuación. Para ello, se han separado las críticas que surgen de la observación individual del crédito, de aquellas realizadas por la agrupación de créditos en carteras.

2.3.3.1 Problemas en la evaluación individual del riesgo

Los problemas que evidencian los modelos de concesión individual crediticia, tratados en este apartado, son de siete tipos:

- a) Una vertiente de críticas es la inexistencia de un marco conceptual y teórico consensuado sobre el cual se han construido estos modelos. A pesar de que existe un número importante de estudios empíricos acerca de los factores que inducen a la quiebra, en la literatura financiera no existe un esquema conceptual claro y ampliamente aceptado que sirva de sustento teórico para construir los modelos de concesión crediticia explicados en este apartado del capítulo. Siguiendo a El y Martellini (2002), existen distintas propuestas parciales que intentan describir circunstancias de fallido, pero no existe acuerdo acerca de los verdaderos procesos que inciden en el incumplimiento de las obligaciones. De ahí que muchas representaciones se concentran en la relación causa-efecto entre patrones financieros y el mismo fallido. Esto ha causado que la construcción de estos modelos (las variables explicativas y su estructura funcional) sea muy diversa y que las variables sean elegidas empíricamente.

- b) Un segundo conjunto de críticas apunta a la elección de las variables que ayudan a la tarea de predicción o clasificación. Debido a que la selección de las variables carece de un marco de consenso y cada investigador realiza dicha tarea influenciado por las particularidades de su conjunto de datos, entonces las variables elegidas pueden tener un escaso poder predictivo en otros conjuntos de datos que se encuentren en diferentes circunstancias. Es decir, si las condiciones subyacentes que causaron una adecuada predicción o clasificación cambian drásticamente, entonces las primitivas variables elegidas por el investigador difícilmente serán útiles para la tarea predictiva. Este problema de falta de generalización hacia otras muestras puede ser minimizado en algún grado por la integración de criterios financieros para la selección de variables. Por ejemplo, la selección de las variables basándose en criterios estadísticos debería llevarse a cabo una vez que ya exista un primer filtro de selección que contemple criterios financieros y/o económicos: de liquidez, rentabilidad, tamaño de las compañías, sectores industriales, etc.
- c) Otro problema es que estos modelos requieren estacionalidad para que puedan utilizarse como buenos predictores. Es decir, para usar un modelo en un contexto predictivo se requiere que las relaciones entre las variables sean estables a través del tiempo. La inexistencia de continuidad en el score utilizado por un modelo para distintas muestras es un problema que se ha identificado en algunos estudios (Barnes, 1987; Rosenberg y Gleit, 1994). Siguiendo a Mensah (1984), esta marcada diferencia en las variables explicativas entre los datos usados para las estimaciones y los usados para las predicciones, podría estar vinculada a cambios económicos (en tasas de interés, la inflación y fases de ciclos de producción). Para solucionar o mitigar esta complicación, en la medida que cambien los datos, suele re-ajustarse o re-entrenarse al modelo en forma continua o regular. Otra solución a este problema es medir la inestabilidad para distintos sectores industriales, países o período temporal e incluirla en el modelo. Un último ajuste que podría utilizarse es el uso de variables deflactadas, siempre y cuando las variables sean valores nominales (no ratios) y la inflación sea relevante (como ocurre en economías de países subdesarrollados o en vías de desarrollo).
- d) Una cuarta complicación para este tipo de modelos es el tratamiento de la variable dependiente en forma dicotómica o discreta. La mayoría de las técnicas estadísticas o de IA usadas para los modelos de concesión de créditos asumen que la variable dependiente toma valores que son excluyentes. La forma más usual es caracterizar a la compañía que ha caído en fallido y distinguirla de que aquella que no lo ha hecho. Sin embargo, en la práctica esta distinción entre “fallido” y “no-fallido” a veces no es clara, incluso algunos autores prefieren reconocer una zona difusa entre ambos estados, conocida como “zona gris”. Además, esta zona gris cobra mayor relevancia por dos tipos de situaciones: (i) porque algunas compañías con reales problemas financieros nunca inscriben la quiebra y (ii) porque empresas estables y con buena salud financiera

pueden inscribir la quiebra por motivos estratégicos (Taffler, 1984). El resultado de asumir inadecuadamente que la variable es dicotómica o discreta, cuando no lo es, teóricamente, puede generar pobres tasas de acierto.

- e) Otro tipo de problemas que adolece este tipo de modelos se refiere a la información contable que se usa para los cálculos. Existen evidencias de que la información contable tiene problemas de fiabilidad o, al menos, algunas empresas distorsionan de una manera sistemática la información contable, de acuerdo a intereses particulares. Ooghe, Joos y de Bourdeaudhuij (1995) y Burgstahler y Dichev (1997) muestran que usualmente las compañías tienen incentivos para controlar sus ganancias y manipular las cuentas anuales. La manipulación de la información por parte de las empresas puede causar mayor inexactitud cuando se usan técnicas predictivas que sean sensibles a ruidos y tergiversaciones, y ello puede causar un análisis distorsionado.
- f) Otra importante crítica a estos modelos que aparece en la literatura financiera se refiere a la suposición de que los costes de errar son iguales. Clasificar a un mal pagador como un cliente adecuado para otorgarle el crédito (conocido usualmente como error tipo I) tiene impacto directo en las distribuciones de pérdidas. Sin embargo, errar en la clasificación de un cliente que paga conforme a los plazos y condiciones del contrato de deuda (error que se conoce como tipo II), sólo repercute en el coste marginal de oportunidad. Por lo tanto, el impacto de este último es menor. West (2000) se considera que el costo del error tipo I es cinco veces mayor que el tipo II para créditos de consumo.

Una posible solución a este problema es crear una serie de escenarios con distintos puntos de corte o agrupaciones, según sea el caso, con sus respectivos costes, y elegir aquel que minimice el coste total de pérdidas crediticias (Pompe y Bilderbeek, 2000). Otra solución es utilizar técnicas que permitan la inclusión del coste de errar en el algoritmo de solución óptima, como ocurre con los árboles de decisión.

- g) Otra fuente de críticas y dificultades proviene del efecto temporal. El tiempo influye desde dos perspectivas a este tipo de modelos: en el proceso de estimación y en el horizonte temporal del análisis. La primera crítica que se hace hacia estos modelos es que no incorporan realmente el tiempo, sino que las aproximaciones son estáticas. Es decir, ignoran el comportamiento de los datos de las compañías a través del tiempo. A pesar de que las bases de datos contienen valores de distintas fechas, muchas investigaciones no incluyen en la modelación la relación temporal entre las variables (Platt y Platt, 1990; Dhumale, 1998). Frente a este problema, pudiera ser más prudente y acorde utilizar análisis de forma transversal, es decir, a cada período de tiempo le corresponde una estimación y validación distinta.

Intentando una solución a dicho problema, Theodossiou (1993) ha desarrollado un modelo financiero predicción de impago que considera el comportamiento de series de tiempo de las variables aleatorias. Este modelo, denominado “Cumulative Sums” (CUSUM), supone que $x_{it} = (x_{1it}, x_{2it}, \dots, x_{git})$ es el vector de g variables para i empresas en el momento t , cuya secuencia es estacionaria, $E(x_{it} | h) = \mu_h$, y la serie temporal está dada por

$$\begin{aligned}
 x_{it} &= \alpha_{fs} + \alpha_h + x_{it}' \beta + \varepsilon_{it}, \text{ para } s = 1, 2, \dots, m, \\
 \alpha_{fs} &= 0 \text{ para cada compañía no fallida y } s > m, \\
 E(\varepsilon_{it}) &= 0, E(\varepsilon_{it}' \varepsilon_{it}) = \Sigma \text{ y } E(\varepsilon_{it}' \varepsilon_{jr}) = 0, \text{ para } i \neq j \text{ y/o } r \neq t
 \end{aligned}$$

Ecuación 5

donde $\varepsilon_{it} = (\varepsilon_{1it}, \varepsilon_{2it}, \dots, \varepsilon_{git})$ es un vector de errores i.d.d. con media cero y matriz de varianza-covarianza Σ , $\alpha_h = (\alpha_{1h}, \alpha_{2h}, \dots, \alpha_{gh})$ es un vector de interceptos de compañías no fallidas, α_{fs} es un vector de desviaciones desde las α_h asociadas con vectores atributos para compañías fallidas extraídas s años antes del fallido y β es una matriz de $g \times g$ de coeficientes. Este tipo de modelos con series temporales puede ser considerado una excepción, ya que la mayoría sólo incluye en la estimación las variables para cada período, y cuando más algunas de ellas tienen alguna variable retarda entre uno a cuatro períodos.

La segunda crítica relacionada con el efecto temporal que se le puede hacer a este tipo de modelos es que la dimensión temporal es estática. Es decir, la mayoría de las investigaciones que utilizan los modelos basados en datos contable-financieros sólo consideran la evaluación de riesgo en un único momento de tiempo, pero no es posible estimar el momento del fallido. Cuando más, en algunas oportunidades, los modelos propuestos utilizan datos contables de v años antes del fallido, asumiendo que la estructura de estas relaciones permitirá pronosticar el fallido a v años. Por ejemplo, Back, Laitinen, Sere y van Wezel (1996) analizan distintas técnicas estadísticas y de IA para predecir la quiebra de compañías a 1, 2 y 3 años antes del momento de fallido. Sin embargo, la elección del momento en que se desea hacer el análisis no es flexible una vez construido el modelo.

2.3.3.2 Dificultades en la evaluación como cartera

Los modelos de evaluación del riesgo para la concesión crediticia que se han presentado en este apartado sólo se han orientado hacia la estimación individual, dejando fuera de la modelación los efectos de la agregación de deudores en carteras crediticias. Esta es una notable limitación, ya que existen evidencias de importantes efectos que deberían incluirse en la modelación, y de esta forma dimensionar las verdaderas consecuencias en el riesgo crediticio. Una adecuada regla de decisión para la concesión de créditos debería contemplar el efecto que tienen las correlaciones entre los deudores y

las correlaciones entre los deudores y la economía. Existen evidencias de que los ciclos económicos no afectan de la misma manera a todos los sectores industriales. Taylor (1998) asiente que el fallido de compañías de EUA entre los años 1984 y 1995 estaría condicionado al contexto económico y que no afecta a todos los sectores industriales de la misma forma. La Tabla 12 muestra las correlaciones entre tasas de fallido (global y sectorial) y cuatro indicadores económicos (crecimiento, variación del crecimiento y dos desfases temporales respecto de ambas). Las correlaciones negativas de todos los sectores industriales entre el crecimiento y las tasas de fallido pueden suponer que en un estado de expansión económica las tasas de fallido descienden (y viceversa); aunque esta relación no tiene la misma intensidad en todos los sectores industriales. Aun más, la correlación entre la variación del GDP (% Chg. Gdp) y las tasas de fallido no tiene la misma dirección (signo) en todos los sectores industriales. Por ejemplo, *Services* tiene una alta correlación positiva con la variación del GDP (0,82) y una correlación negativa (-0,4) con el sector financiero.

Tabla 12. Correlaciones entre tasas de fallido e indicadores económicos

	Manufac- turing	Retail	Transp., Comm.	Wholesale	Construc- tion	Finance, Insurance & Real Estate	Services	Total
Real Gdp.	-0,42	-0,72	-0,76	-0,54	-0,09	-0,01	-0,69	-0,38
% Chg. Gdp.	0,05	0,38	0,15	0,03	-0,22	-0,40	0,82	0,16
Lagging vs. Gdp.	0,38	-0,72	-0,71	-0,49	-0,03	0,07	-0,66	-0,37
Lag vs. chg. Gdp.	-0,34	0,11	0,10	-0,28	-0,46	-0,66	0,14	-0,21

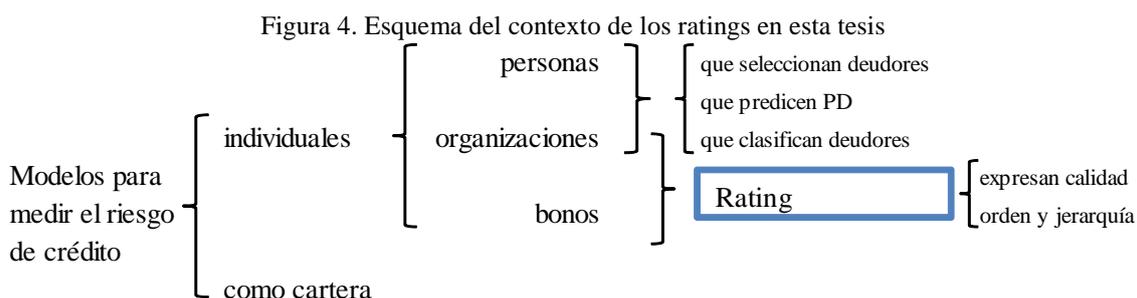
Nota: Datos publicados por Dun & Bradstreet de compañías de EUA entre 1984 y 1995.
Fuente: Taylor (1998), Exhibit 3.

Teóricamente, es posible distinguir entre dos mecanismos que generan dicha correlación: la cíclica y el contagio de fallidos. La correlación cíclica entre empresas se debe a su dependencia por factores macroeconómicos comunes, mientras que el contagio entre empresas en fallido, se refiere a directos vínculos entre una compañía con las restantes, por ejemplo, a través de la relación de una matriz con su subsidiaria. Giesecke (2002) estudia la correlación entre empresas y a la correlación cíclica, y concluye que el aumento de transparencia informativa de las características de las empresas relacionadas reduce la probabilidad de efectos del contagio. Respecto de la correlación cíclica, Rösch (2003) descubre que la introducción de variables proxy de correlaciones del ciclo económico puede generar proyecciones más adecuadas de distribuciones de pérdidas, generando menor incertidumbre en la medición de los potenciales fallidos.

2.4 Modelos que replican el rating

Hasta aquí se han expuesto diversas formas de como medir el riesgo de crédito, teniendo siempre presente el objetivo de esta tesis. En la sección anterior se expusieron los enfoques de medición individual, donde el rating es uno de ellos (ver Figura 4). Se ha dejado esta sección para exponer separadamente las investigaciones realizadas por otros autores donde se hace réplica de rating, debido

a la importancia en esta tesis. Concretamente, desde los años sesenta distintos investigadores han intentado replicarlos, utilizando diferentes enfoques y técnicas (Horrigan, 1966; Pogue y Soldofsky, 1969; West, 1970; Pinches y Mingo, 1973; Kaplan y Urwitz, 1979). En esencia, todas las investigaciones no intentan repetir el proceso que realizan especialistas financieros de las agencias calificadoras, sino que intentan relacionar el rating con aquellas características del deudor y/o del instrumento de deuda que creen relevantes. Este proceso de réplica se realiza sin conocer toda la información que las agencias recogieron para emitir la calificación, debido a que éste es un proceso privado que realizan agencias como S&P.



Fuente: elaboración propia

En general, el rating replicado puede ser de una empresa (Rovira, Agell et al., 2004, Campos, Ruiz et al., 2004; Moro, 2004; Ahn y Kim, 2011), o el rating de bonos de una empresa, de una institución sin fines de lucro o de una agencia de gobierno (Horrigan, 1966; Garavaglia, 1991, Maher y Sen, 1997; Lee, 2007).

Una forma de establecer la relación entre la información del deudor y/o del bono (en el vector x) y los ratings emitidos por las agencias calificadoras (el vector y) es la expresada en la Ecuación 4. Las K clases de ratings están agrupadas en Ω grupos ($\Omega = 2, 3, \dots, K$), donde el número de grupos depende del objetivo del estudio. En esta modelación, el output es la clasificación misma que se predice o bien, es un parámetro que permite predecir a qué grupo o clase pertenece.

En la literatura financiera se puede encontrar una gran semejanza entre las aproximaciones para la concesión de crédito y los modelos de réplica de rating. Estas similitudes están presentes en las variables utilizadas para caracterizar los atributos de los deudores, en las técnicas de clasificación o predicción y en las metodologías de validación de los resultados, entre otras. El motivo por el que aparecen estas similitudes es que ambos tipos de modelos se refieren a la medición del riesgo crediticio de empresas.

Por otro lado, también hay diferencias entre los estudios de concesión de crédito y aquellos que replican el rating. La primera de ellas se debe al sujeto de evaluación, ya que los estudios de concesión

de créditos suelen apuntar a personas y empresas, en cambio los de rating apuntan fundamentalmente a compañías. Esto genera diferencias en cuanto a la medición de la bondad de ajuste y la formulación del modelo. Respecto de la bondad del ajuste, los estudios de concesión crediticia suelen medir la eficiencia del objetivo trazado en términos de tasas de acierto, tanto sea de tipos de deudores como de probabilidades de ocurrencia (usualmente PD), en cambio, en los trabajos de réplica se centran en las tasas de acierto logradas. Respecto de la formulación del modelo, los trabajos de concesión de crédito suelen usar variables asociadas al sujeto de crédito (personas o bien compañías), y por lo tanto, la naturaleza de las variables cambia bastante entre uno y otro tipo de investigación. En los estudios de réplica de rating suele estar más centrado el análisis de compañías y por tanto, el modelo usado y sus variables son muy similares; aunque la excepción está en el tipo de industria o sector económico que se ha elegido analizar. En este punto, la industria que utiliza un distinto tipo de variables es la banca. Debido al interés que ha cobrado la medición del riesgo crediticio bancario bajo la propuesta de Basilea II, en el última década hay estudios en este sector industrial (Ravi, Kurniawan, Thai y Kumar 2008; Ögüt, Donağay, Ceylan y Atkaş, 2012). En adelante, y de acuerdo con el objetivo de esta tesis se referirá siempre a rating de compañías no bancarias, debido a que esta es una línea muy diferente.

2.4.1 Relación entre rating y características de las compañías

Los diversos modelos de réplica de ratings han intentado incorporar distintos grupos de variables que permitan capturar las características financieras y operativas de la compañía, y de aquellos atributos de la empresa evaluada que los expertos financieros creen relevantes para la calificación crediticia. Como lo expresa Pogue y Soldofsky (1969, página 207), “los ratings de bonos pueden depender de datos de las condiciones financiera y operacionales de la compañía de fácil acceso (por ejemplo, medidas de endeudamiento, cobertura de ganancias, inestabilidad de las utilidades y rentabilidad). Además, estos ratings pueden depender del juicio del evaluador acerca de aspectos que no son usual y fácilmente mensurables: la calidad de la administración, cambios futuros en los preferencias de los clientes y en la tecnología que influyan en las ganancias de largo plazo, etc.”¹⁰. Estas características se pueden clasificar de la siguiente forma: a) la identificación del tipo de deuda (si corresponde) o de las características no financieras de la compañía, b) su tamaño, c) su nivel de actividad, d) su estructura de financiación, e) su liquidez, f) su rentabilidad y g) su variabilidad en el mercado de capitales. En la Tabla 13 se muestra un resumen de los tipos de las variables más utilizadas en los trabajos de réplica de rating junto a las referencias más relevantes y ejemplos de variables de cada tipo. La relación de cada variable con cada investigación se encuentra en la Tabla A 2 del Anexo A.

¹⁰ Cita textual de la traducción realizada por el autor de esta tesis: “... bond ratings may depend on readily available statistics on the firm’s financial conditions and operations (for example, measures of leverage, earnings coverage, earnings instability, and profitability). Bond ratings also may depend on the rater’s judgment about factors that are not usually or easily measured: quality of management, future changes in tastes and technology that influence long-run profit possibilities, etc.”

Tabla 13. Variables de algunos modelos con fines de réplica de rating.

Tipo de variable	Ejemplos del tipo de variable	Referencias
tamaño	Log of total assets ; total assets; Issue size; total debt; sales; stockholders' equity	Pinches y Mingo (1973), Horrigan (1966), Kaplan y Urwitz (1979), Surkan y Singleton (1990), Maher y Sen (1997), Chaveesuk et al. (1999), Shin y Han (2001), Huang, Chen et al. (2004), Moro (2004), Lee (2007), Ahn y Kim (2011)
actividad	Cash flow before interest and taxes / interest charges; CV of net income; CV of total assets; depreciation / total expense; revenue growth rate; sales /net worth; financial expense / sales	Horrigan (1966), Kaplan y Urwitz (1979), Dutta y Shekhar (1988), Surkan y Singleton (1990), Shin y Han (2001), Moro (2004), Lee (2007), Ahn y Kim (2011)
financiación	Cash flow / current debt; total liabilities / total assets; Long-term debt / total assets; Long-term debt / net worth; Total debt / total capital; Shareholders' equity + long-term debt / fixed assets	Pinches y Mingo (1973), Horrigan (1966), Kaplan y Urwitz (1979), Dutta y Shekhar (1988), Surkan y Singleton (1990), Maher y Sen (1997), Chaveesuk et al. (1999), Shin y Han (2001), Huang, Chen et al. (2004), Moro (2004), Lee (2007), Ahn y Kim (2011)
liquidez	Liability / Cash Assets ; Current assets / current liabilities; Current assets / sales; Net working capital / sales; receivables + inventory / total assets; Quick ratio	Horrigan (1966), Dutta y Shekhar (1988), Chaveesuk et al. (1999), Shin y Han (2001), Huang, Chen et al. (2004), Moro (2004), Lee (2007), Ahn y Kim (2011)
rentabilidad	Net income / total assets; EBIT / total assets; Operating income / total assets; Retained earnings / total assets; EBIT / interest; return on investment (or equity); net operating profit / sales; earning/fixed costs; Earnings per share; Non-operating income/sales; Operating income/received capitals; Operating profit margin	Pinches y Mingo (1973), Horrigan (1966), Kaplan y Urwitz (1979), Dutta y Shekhar (1988), Surkan y Singleton (1990), Maher y Sen (1997), Chaveesuk et al. (1999), Shin y Han (2001), Huang, Chen et al. (2004), Moro (2004), Lee (2007), Ahn y Kim (2011)
volatilidad	market's beta of each company ; standard desviation of market's return	Kaplan y Urwitz (1979), Maher y Sen (1997)
características	Firm classification; firm type; subjective prospect of company; subordination status; years after founded; years of consecutive dividends	Pinches y Mingo (1973), Horrigan (1966), Kaplan y Urwitz (1979), Dutta y Shekhar (1988), Maher y Sen (1997), Shin y Han (2001), Ahn y Kim (2011)

Fuente: Elaboración propia.

Para verificar la similitud que tienen las variables de los modelos que replican rating con aquellos modelos de scoring se puede comparar las variables en la Tabla 7 y en la Tabla 13. Un listado completo y extendido de estas variables está disponible en la Tabla A 1 y en la Tabla A 2 del Anexo A. Se ha optado por esta clasificación de variables debido a que ésta tipología responde a elementos estructurales o característicos de las compañías y que suelen ser tomados en cuenta por los expertos financieros cuando realizan sus análisis (Bessis, 2002).

Un tipo de información importante para la réplica de ratings de bonos es el tipo subordinación que tiene la deuda. En Horrigan (1966), se utiliza una variable dummy (una dicotómica) para identificar si el bono era o no deuda subordinada (las restantes eran ratios financieras). También se han usado variables dicotómicas para indicar la subordinación de la deuda en Kaplan y Urwitz (1979), Pinches y Mingo (1973) y Maher y Sen (1997). Asimismo, se han empleado variables que indican la pertenencia de la compañía a un sector industrial o a un conglomerado (Shin y Han, 2001; Dutta y Shekhar, 1988).

Adicionalmente, se han incluido variables que se relacionan indirectamente con el default de la compañía, como por ejemplo la opinión de las firmas auditoras acerca de los Estados Financieros de las empresas, litigios en los que está implicado el deudor, o políticas de dividendos (Pinches y Mingo, 1973; Keasey y Watson, 1987; Flagg y Giroux, 1991; Wilson et al., 1995; Spathis, 2003).

La variable de tamaño más utilizada en problemas de predicción de rating es el total de activos de las empresas (Horrigan, 1966; Kaplan y Urwitz, 1979; Pinches y Mingo, 1973; Maher y Sen, 1997; Huang, Chen, Hsu, Chen y Wu, 2004). También se han utilizado como variables de tamaño el monto de la emisión (Pinches y Mingo, 1973), el total de ventas (Surkan y Singleton, 1990), el total del capital (Horrigan, 1966; Kaplan y Urwitz, 1979; Maher y Sen, 1997; Huang, Chen, et al., 2004) y el total de la deuda corporativa (Chaveesuk, Srivaree-Ratana y Smith, 1999; Huang, Chen, et al., 2004). Existe la creencia de que el tamaño está vinculado con la capacidad de afrontar crisis financieras, o sea, a mayor tamaño de la compañía, mejor es la calificación de la agencia. Una evidencia que apoya esta creencia se encuentra en Huang, Chen, et al. (2004), quienes midieron la contribución que hacían las variables en la predicción de rating, concluyendo que las variables que tenían mayor poder predictivo para su muestra de datos de EUA fueron dos variables de tamaño (total activo y total pasivo) y una de financiación (total deuda de largo plazo sobre el total capital pagado).

Las variables de actividad regularmente hacen referencia a las ventas de las compañías, ya sea como un cociente o como una tasa de crecimiento (Horrigan, 1966; Dutta y Shekhar, 1988, Surkan y Singleton, 1990). Todas las variables de actividad intentan capturar la velocidad de las operaciones, como por ejemplo la carga de intereses pagados respecto de los gastos totales (Kaplan y Urwitz, 1979; Shin y Han, 2001). La relación entre el rating y el nivel de actividad es importante ya que este tipo de ratios indica el ritmo de actividades que tiene la compañía, es decir, si los proyectos que ésta tiene le permiten el adecuado pago de sus compromisos.

Las variables relacionadas con la financiación de las compañías suelen referirse a la proporción entre la deuda (de corto o largo plazo) y el total activo (Shin y Han, 2001; Dutta y Shekhar, 1988, Chaveesuk et al., 1999) o entre la deuda y el patrimonio (Kaplan y Urwitz, 1979; Huang, Chen, et al., 2004). También es frecuente el uso de ratios de liquidez compuestas por el activo circulante y/o el pasivo circulante. En este tipo de ratios, se utilizan cocientes o diferencias entre ambos componentes del circulante o como proporción del capital o del activo (Chaveesuk et al., 1999; Dutta y Shekhar, 1988). La finalidad de las ratios de liquidez es capturar información de la compañía que indique si su situación financiera para enfrentar el pago inmediato de sus obligaciones es apropiada o no, y como es la estructura de financiación.

Otros ratios usados para predecir rating miden la rentabilidad que obtiene la compañía en un período de tiempo. Estas ratios miden la eficiencia, a través de partidas del mismo Estado de Resultados (Horrihan, 1966; Pinches y Mingo, 1973; Dutta y Shekhar, 1988; Huang, Chen, et al., 2004), o bien, respecto de los montos invertidos en la compañía (Surkan y Singleton, 1990; Kaplan y Urwitz, 1979).

La volatilidad de los precios accionarios de la compañía evaluada es otro elemento que se ha incluido en este tipo de aproximaciones (Kaplan y Urwitz, 1979; Maher y Sen, 1997). Su objetivo es medir el grado de incertidumbre que el mercado percibe y materializa en la cotización bursátil de las acciones de la compañía. Sin embargo, este tipo de variables también puede incluir efectos distintos a la calidad crediticia, y que tengan más relación con las fluctuaciones propias del mercado de capitales. Por ello, su capacidad para predecir la calidad crediticia del deudor no es de total consenso.

Algunos autores exponen los tipos de relación que hay entre las variables y la calidad crediticia del deudor (Kaplan y Urwitz, 1979; Pinches y Mingo, 1973; Glantz, 2003; Bessis, 2002). Sin embargo, no existe una armonización de cuál es el sentido y magnitud de dicha relación. Probablemente esto se deba a que existen muchas variables y que las relaciones suelen ser más evidentes cuando se usan técnicas estadísticas y no cuando se utilizan técnicas de Inteligencia Artificial. A pesar de ello, de la revisión de la literatura, el autor de esta tesis ha recogido resumidamente las relaciones que potencialmente pueden tener las variables con el rating y que se exponen a continuación.

- a) Tamaño de la compañía: relación directa, debido a que suele ocurrir que la magnitud de las inversiones, capital y la participación en el mercado influyen positivamente en el rating que conceden las agencias calificadoras.
- b) Nivel de actividad de la compañía: relación directa si el indicador está relacionado con la eficiencia de las empresas; es decir, si la compañía es más eficiente, y por ende el indicador de actividad es mayor, entonces el rating podría ser de mejor calidad. Esta no es una relación muy clara para todos los indicadores de actividad y puede ser que se encuentre una relación inversa. Todo dependerá, por lo tanto, del tipo de indicador.
- c) Estructura de financiación: si está relacionado con el endeudamiento, la relación suele ser inversa, ya que a mayor endeudamiento, la posición de la calidad crediticia suele ser menor. En cambio, si se refiere a la financiación con fondos propios, esta relación suele ser positiva, ya que la incorporación de dinero de los mismos dueños de la compañía es una inyección de recursos disponibles para cubrir las obligaciones corporativas.
- d) Liquidez de la compañía: relación positiva, ya que en la medida que la liquidez es mayor, la capacidad de pago de los compromisos corporativos es mayor, y por lo tanto, la calificación crediticia también lo es.
- e) Rentabilidad corporativa: suele tener una relación positiva, debido a que en la medida que la rentabilidad es mayor, la compañía puede tener una mayor cantidad de recursos disponibles para

afrontar el pago de obligaciones. No obstante, esta relación no es tan fuerte, ya que puede ocurrir que determinadas empresas usen el excedente de las operaciones para realizar más proyectos de inversión que compliquen la capacidad crediticia de la misma compañía.

- f) Variabilidad en el mercado de capitales: relación inversa, ya que una mayor variabilidad puede ser un indicador de mayor riesgo que corre la compañía y es percibido en el mercado de capitales.

2.4.2 Selección de las variables para replicar el rating

Con todo este abanico de variables, los investigadores utilizan criterios estadísticos y financieros para seleccionar las variables que les permitan replicar el rating y lograr la generalización del modelo. Es decir, los investigadores utilizan similares procedimientos para elegir las variables que los usados en los modelos de concesión de créditos, ya descritos en la sección 2.3.2 (página 27). No obstante, existen metodologías de selección particularmente diferentes, que constituyen una excepción: Shin y Han (2001), han aplicado una encuesta a 7 expertos financieros de agencias de rating y de banca comercial para elegir las variables de su modelo. Los expertos han asignado la importancia relativa que ellos dan a las variables propuestas por los investigadores.

Además de elegir las variables que ayudan a replicar el rating, los investigadores escogen las clases de rating que replican o una agrupación de estos ratings. Esta elección influye inversamente en la tasa de aciertos: a mayor granularidad (cuando Ω es grande o cercano al K máximo), menor es la tasa de aciertos; y viceversa. La Tabla 14 contiene el promedio de las tasas de acierto de estudios con igual número de grupos de rating, basados en una selección de estudios expuestos en la Tabla 15. Por ejemplo, Garavaglia (1991) utiliza un modelo con 17 clases de rating cubriendo todo el espectro de calificaciones posibles (desde la máxima calidad crediticia que es AAA, hasta el más bajo rating, D) y otro modelo con tres grupos de clases de rating: un grupo con grado de inversión (desde AAA hasta BBB), otro con grado especulativo (desde BB hasta C) y un último que sólo contempla las compañías con rating D. En el primero de los modelos de este autor, se pretendía replicar el rating con un gran grado de granularidad (logrando un 23% de aciertos); mientras que en el segundo de los modelos se pretendía conseguir un mayor nivel de aciertos con una clasificación que tuviese sentido financiero (logrando un 84% de aciertos).

Tabla 14. Promedio de tasas de acierto según el N° de grupos de rating

N° de grupos de rating	2	3	4	5	6	9	17
Promedio de acierto (%)	81	84	75	70	50	59	25

Dos aspectos relevantes que se pueden advertir de la revisión de la literatura financiera se refieren (1) al tipo de rating que se replica y (2) al origen de las compañías incluidas en los estudios. La mayoría de las investigaciones replican ratings de bonos, mientras que pocos lo hacen sobre la calificación realizada a la empresa misma. En la Tabla 15 se puede observar que sólo en 3 de 20 estudios se han

utilizado ratings de compañías, en vez de ratings de bonos. Cabe notar que si en el modelo no se especifica información acerca del tipo de deuda a la que hace referencia el rating (por ejemplo, con una variable que indique si es deuda subordinada), es más sensato utilizar el rating que la agencia hace de la compañía y no el rating de un tipo específico de título de deuda. Por ejemplo, en Horrigan (1966), Pinches y Mingo (1973), Kim, Weistroffer y Redmond (1993) y Maher y Sen (1997) se usa una variable que identifica el tipo de los ratings de bonos. En contra de esta opinión, en Huang, Chen, et al. (2004), Shin y Han (2001) y Chaveesuk et al. (1999) se replican los ratings de bonos, pero no se especifica el tipo de deuda a que hace referencia cada una de las calificaciones. El segundo aspecto que resalta luego de revisar la literatura financiera es que la mayoría de los estudios que replican ratings utilizan datos de compañías de EUA en 3 de los 20 estudios de la Tabla 15 se han usando datos de ratings distintos a los estadounidenses. Sólo en los últimos años se han utilizado datos de otros países del mundo.

Tabla 15. Artículos publicados de réplica de ratings

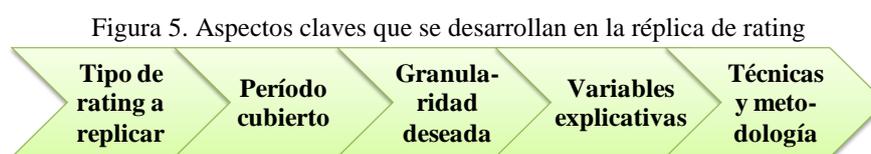
Artículo	clases	tipo de clases	variables	acierto (%)	Sujeto de rating	País
Horrigan (1966)	9	AAA ... C	6	52 - 58	Bonos	EUA
Pogue y Soldofsky (1969)	4	Aaa ... Baa	6	80 ⁽¹⁾	Bonos	EUA
West (1970)	9	Aaa...Baa	4	62	Bonos	EUA
Kaplan y Urwitz (1979)	6	Aaa ... B	10	55, 50	Bonos	EUA
Pinches y Mingo (1973)	5	Aa ... B	6	58 - 65	Bonos	EUA
Dutta y Shekhar (1988)	2	AA v/s noAA	10	65 a 92	Bonos	EUA
Surkan y Singleton (1990)	2	Aaa v/s A1,A2,A3	7	88	Bonos	EUA
Garavaglia (1991)	17	AAA, ..., B-, (CCC,....,D)	87	23	Bonos	EUA
	3	I, E, M	87	84	Bonos	EUA
Utans y Moody (1991)	17	AAA ... B-	10	21 a 30	Bonos	EUA
Han y Jhee (1993)	4	A1 ... B	26	54 a 91	Bonos	Corea
Kim et al. (1993)	6	Aaa ... B	8	36 a 43	Bonos	EUA
	6	Aaa ... B	8	31 a 55	Bonos	EUA
Moody y Utans (1994)	17	AAA ... B-	10	21 a 31	Bonos	EUA
	5	AAA ... B-	10	63 - 85	Bonos	EUA
Maher y Sen (1997)	6	Aaa ... B	7	62 a 70	Bonos	EUA
Kwon et al. (1997)	5	A1 ... C	26	58 a 74	Bonos	EUA
Chaveesuk et al. (1999)	6	AAA... B	8	48 a 53	Bonos	EUA
	6	AAA... B	8	37 a 57	Bonos	EUA
Shin y Han (2001)	5	A1... C	12	59 a 62	Bonos	Corea
	5	A1... C	12	62 - 70	Bonos	Corea
Rovira et al. (2004)	2	I v/s (E+M)	21	79	Compañías	EUA+E+C+J
Huang et al. (2004)	5	AAA...BB	6	73 a 80	Bonos	Taiwán
	5	AAA...BB	16	70 a 76	Bonos	Taiwán
	5	AA... B	5	75 a 81	Bonos	Taiwán
	5	AA... B	14	75 a 80	Bonos	Taiwán
Moro (2004)	2	AAA v/s BB	13	62 a 100	Compañías	EUA
Rovira et al. (2005)	2	I v/s (E+M)	32	73 a 89	Compañías	EUA+E+C+J
		I v/s (E+M)	10	81 a 85	Compañías	EUA+E+C+J
Lee (2007)	5	AAA, AA, A, B, C	10	58 a 63	Bonos	Corea
		AAA, AA, A, B, C	10	55 a 60	Bonos	Corea
		AAA, AA, A, B, C	10	35 a 67	Bonos	Corea
Ahn y Kim (2011)	5	A1, A2, A3, B+C	10	65 a 70	Compañías	Corea
		A1, A2, A3, B+C	14	67 a 76	Compañías	Corea

Nota: **I** indica clase de grado de Inversión (rating AAA...BBB) y **E** grado Especulativo (rating BB...CCC); y **M** significa Mala o la peor calidad crediticia (rating D); **EUA+E+C+J** significa que los datos son de compañías situadas en Estados Unidos de Norteamérica, en Europa, en Canadá y en Japón, respectivamente.

Respecto de las técnicas y los niveles de acierto de estos modelos, las investigaciones han sido muy variadas. Uno de los primeros trabajos es el de Horrigan (1966), quien obtuvo hasta un 58% de predicciones correctas de rating (de 9 clases) para 200 bonos norteamericanos entre 1961 y 1964. Para ello utilizó regresiones lineales con 15 diferentes variables financieras. West (1970) logró un 62% de aciertos para ratings (de 9 clases) de bonos corporativos norteamericanos de 1953 y 60% de aciertos para datos de bonos de 1961. Pinches y Mingo (1973) utilizan análisis discriminante, obteniendo un 65% y 56% de aciertos para dos conjuntos de datos de bonos norteamericanos con rating (de 5 clases) que pertenecen a los años 1967-1968 y 1969, respectivamente. Kaplan y Urwitz (1979) utilizan dos conjuntos de muestras de bonos corporativos de EUA (de 6 clases). Una de ellas contiene bonos con rating sin cambios o transiciones (entre 1971 y 1972) y la otra posee bonos recién emitidos (en 1970 y 1974). Con sus modelos logra niveles de aciertos del 69% y del 55%, respectivamente. En la Tabla 15 se muestran estos resultados en forma comparada.

Investigaciones posteriores han intentado mejorar las predicciones y subsanar problemas que tienen las técnicas empleadas para la réplica (los problemas de las técnicas utilizadas son explicados en el siguiente capítulo). Dutta y Shekhar (1988) utilizan una red neuronal y comparan estos resultados con los obtenidos con análisis discriminante y regresión lineal. En este caso la red neuronal clasificó con mayor precisión los ratings. Su objetivo era clasificar bonos en dos clases: AA o distinto de AA, utilizando variables financieras de los trabajos de Horrigan (1966) y Pinches y Mingo (1973). En la Tabla 15 no aparecen las distintas técnicas utilizadas, con la intención de no anticipar el tema tratado en el siguiente capítulo. No obstante, en caso de que el lector desee contrastar los resultados comparando las distintas técnicas, puede ver éstos y otros detalles en la Tabla A3 del Anexo B.

En resumen, la réplica de rating comenzó a realizarse a finales de la década de los sesenta, con estudios acerca de bonos de algunas pocas compañías de EUA. Desde entonces, se han implementados variados modelos con diversas variables, técnicas de cálculo y agrupaciones de rating. En las últimas décadas se han desarrollado nuevos modelos de réplica de ratings que intentan incluir calificaciones de países distintos de EUA y con nuevas técnicas, especialmente de IA (Rovira et al., 2004; Huang, Chen, et al., 2004). Lo que se intenta en cada uno de estos nuevos estudios es aumentar la precisión, sobre todo cuando la sobrestimación de la calidad crediticia (clasificar con buen ratings a un mal deudor) tiene mayores costos financieros que la subestimación (Frydman et al., 1985; West, 2000). Los estudios revisados tienden a desarrollar un conjunto de temas que se refieren a la réplica de rating (ver Figura 5) y que a continuación se exponen como preguntas clave.



Fuente: elaboración propia.

- a) *¿Qué tipo rating se desea replicar?*, teniendo como alternativas los ratings de bonos versus los de organizaciones; o los de empresas lucrativas versus los ratings de organizaciones sin fines de lucro; o si se tratará de empresas bancarias o de otro tipo de industria, si el rating es de largo plazo o de corto plazo, o si se refiere a moneda local o extranjera, etc.
- b) *¿Qué período de tiempo se desea cubrir?* En la medida que éste sea un único período de tiempo la pregunta estará condicionada a los datos que se tengan a disposición. Sin embargo, si se tienen datos de más de un período de tiempo una pregunta que debería hacerse el investigador es acerca de si se reconoce y modela la posibilidad de la existencia de autocorrelación temporal entre rating de diferentes momentos de tiempo y que sean del mismo deudor calificado.
- c) *¿Qué tipo de granularidad se desea?* En este sentido, la mayoría de los estudios han realizados las separaciones entre grado de inversión y grado de especulación, y entre clases agregadas versus todas las clases posibles que se tengan. Naturalmente, esta decisión condicionará el grado de acierto que se obtendrá en la réplica. A mayor número de clases, mayor es el grado de errores potenciales en la réplica.
- d) *¿Qué variables explicativas se usarán y/o cómo seleccionarlas?* Los estudios revisados han elegido entre variables obtenidas desde los estados financieros de las compañías o desde la información del mercado bursátil; aun cuando también se podrían incluir indicadores sectoriales o de la industria. Luego el investigador suele usar unos criterios de selección de dichas variables que suelen ser económico-financieros o estadísticos.
- e) *¿Qué metodología y técnicas se usarán para replicar?* Los artículos revisados suelen usaran metodologías de diseño de muestreo, de entrenamiento/ajuste de datos y de validación que ayuden a la réplica y permitan la generalización en otros conjuntos de datos. Este tópico es desarrollado en el siguiente capítulo de esta tesis.

2.4.3 Virtudes y críticas de los modelos de réplica de ratings

Los modelos que replican los ratings tienen como principal ventaja la fácil interpretación de sus resultados predictivos. No obstante, al igual que los mismos ratings, los modelos de réplica no permiten realizar una completa medición del riesgo de crédito. Sólo es posible utilizarlos para medir el riesgo por incumplimiento y por cambio de la calidad crediticia (en la medida que se acepte la migración como una proxy adecuada de dicho cambio).

Otra ventaja que ofrecen estos modelos de réplica es que la predicción podría utilizarse como un rating cuando la compañía o instrumento de deuda no tiene calificación crediticia. Esta es una fortaleza debido a que el universo de compañías que tiene alguna asignación de rating es reducido. Por ejemplo, S&P emitió 12.413 ratings para compañías estadounidenses con deuda de largo plazo en moneda local

en 2002 – según base de datos proporcionada por S&P y utilizada en Proyecto MERITO¹¹ – y Moody's emitió aproximadamente 2.500 calificaciones para bonos de compañías de EUA en 1997 (Carty, 1997); en contraste el número de compañías registradas en el Censo del año 2002 fue de 5.697.759 (US Census Bureau, 2006). En otras palabras, el número de empresas y bonos de EUA con calificación crediticia fue menos del 0.2% del total de empresas registradas en 2002. A pesar de que esta es una significativa ventaja, cabe advertir que para predecir el rating de una compañía o bono que no tenga calificación externa se deben cumplir al menos los siguientes requisitos:

- (a) Las características de la compañía o instrumento de deuda del rating a predecir deben ser similares a las del conjunto de datos sobre los que se basaron los procesos de ajuste o entrenamiento. Por ejemplo, si la muestra sobre la cual se aplicó inicialmente el modelo incluía sólo a grandes compañías del sector farmacéutico de países de la Unión Europea, entonces la réplica no se podrá aplicar a una empresa del sector de telecomunicaciones israelí. En este caso las diferencias están dadas tanto por el tipo de sector financiero como la diferencia de riesgo país de ambos mercados.
- (b) El segundo requisito es que las condiciones externas a la compañía (o del entorno) sean similares a aquellas sobre las cuales se realizó el proceso de entrenamiento. Las condiciones externas más relevantes son la situación económica del mercado, y el contexto competitivo y tecnológico. Por ejemplo, si el entrenamiento de los datos de la muestra se realizó cuando la economía estaba en un ciclo expansivo y la predicción se hace para una empresa inserta en un fuerte proceso recesivo, es posible que la predicción del nuevo rating esté sobrevalorada.

Hasta aquí se han expuesto ventajas y virtudes de estos modelos de réplica de rating, pero éstos también adolecen de problemas y críticas. La primera de estas críticas apunta a la falta de un único marco conceptual claro y de consenso de cuáles son las variables que inciden en la réplica del rating. Es posible que esta crítica se vea amplificadas porque las mismas agencias de ratings difieren en cuanto a la metodología que utilizan para otorgar su calificación crediticia. Sin embargo, esta situación está cambiando gradualmente, ya que existen algunos trabajos que proponen principios comunes utilizados por las agencias de rating para la creación de sistemas de rating interno (Krahnén y Weber, 2001; Frerichs y Wahrenburga, 2003).

Otro problema en los modelos de réplica de rating es la inestabilidad de los datos y falta de estacionalidad. Además, todos los problemas relativos a la información contable descritos en el apartado 2.3.3 (de los modelos de concesión crediticia) son aplicables a los modelos de réplica de rating. También la falta de incorporación del efecto temporal en los modelos de réplica de ratings es una limitación cuando se utilizan datos de períodos pasados. La inclusión de ratings de períodos

¹¹ El proyecto MERITO ha sido un proyecto de investigación financiada por el Ministerio de Ciencia y Tecnología del Gobierno de España, cuyo nombre es Análisis y desarrollo de Técnicas Innovadoras de Soft-Computing con Integración de Conocimiento Experto: Una Aplicación a la Medición del Riesgo Financiero de Crédito (TIC2002-04371-C02-02).

anteriores para predecir nuevos ratings puede causar elevadas sobrestimaciones, sobre todos si la estimación de los estadísticos del modelo se realiza con las mismas compañías que se usaron para realizar el ajuste/entrenamiento de datos. En otras palabras, si la autocorrelación temporal no es tratada adecuadamente, las estimaciones pueden ser incorrectas (Theodossiou, 1993). Al igual que este último problema, la mayoría de las críticas a los modelos de concesión de crédito, expuestas apartado 2.3.3 (en la página 40), son aplicables a la réplica de rating y, por lo tanto, no son detalladas en este párrafo.

2.5 La propuesta para replicar el rating en esta tesis

De acuerdo a la revisión de la literatura para cumplir los objetivos propuestos en esta tesis, el autor de la misma propone las siguientes decisiones para la réplica del rating:

- ✓ Que la réplica sea de rating de compañías sobre las cuales se ha emitido una calificación crediticia para un conjunto homogéneo de empresas, excluyendo a aquellas pertenecientes al sector financiero y de seguros (privados o públicos). Para evitar que en la medición del riesgo crediticio influyan otros tipos de riesgo (como el riesgo asociado a las perturbaciones de los tipos de cambio) se aconseja utilizar el rating en moneda local; y también se aconseja usar el rating de largo plazo de las compañías en vez del de corto plazo para evitar perturbaciones que no son capturadas con las variables que se obtendrán desde los estados financieros anuales.
- ✓ Que la réplica sea realizada sólo para un período de tiempo, de tal manera de que no se encuentre contaminada la predicción por problemas de autocorrelación.
- ✓ Que la réplica sea realizada en 7 ú 8 clases agrupadas de rating, del tipo “AAA, AA, A, BBB, BB, B, C y D”. Con esto se pretende que exista una buena granularidad, en el sentido de no permitir exageraciones, como por ejemplo, que existan muchos grupos (AAA, AA+, AA, AA-, A+,A,...CCC, CC, C, SD, D) donde no existan datos, o bien, que sólo existan sólo dos clases (D versus las restantes).
- ✓ Que la réplica sea realizada de una manera comparativa para evaluar el desempeño de diversas técnicas, mediante validación dentro y fuera de la muestra.
- ✓ Que la réplica se realice con un conjunto de variables que se muestran en la Tabla 16, en donde se expone el tipo de relación que se espera tengan en la réplica. Estas variables son de tamaño, actividad, estructura de financiación, liquidez, rentabilidad y variabilidad bursátil. La elección de estas variables se ha hecho conforme a las pautas expuestas en el punto 2.4.1 de este capítulo.

El resto de las propuestas que permitan realizar apropiadamente la réplica de rating son abordadas en el siguiente capítulo, ya que están relacionadas con las metodologías y técnicas a utilizar.

Tabla 16. Relaciones esperadas entre las variables de la muestra y el rating

Variable	nombre	concepto	relación	motivo que respalda la interpretación financiera
ventas	t_vtas	tamaño	directa	tamaño de ventas indica potencial del negocio y ganancias, por lo que, en la medida de que las ventas sean mayores, mejor es la calidad crediticia
valor en bolsa	t_vm	tamaño	directa	tamaño de la compañía se vincula con la capacidad de cumplir obligaciones
rotación operacional	a_s-ta	actividad	directa	mayores ventas relativas al tamaño indican potencialidad del negocio y eficiencia
flujo de efectivo	a_cf-s	actividad	directa	implica la recuperación de las ventas devengadas y eficiencia, es decir, la capacidad para obtener dinero para pagar las obligaciones
variación de ventas	a_vvtas	actividad	directa	implica pujanza o deterioro de la actividad comercial, por lo tanto, un aumento implica una mejora en la calidad crediticia, y una disminución un deterioro en ella.
cobertura sobre la deuda	f_cf-td	financiación	directa	capacidad para cubrir las deudas con los flujos de caja generados por las operaciones habituales.
proporción de deuda de largo plazo	f_ltd-ce	financiación	inversa	a mayor deuda más posibilidades de incumplimiento
financiación de infraestructura	f_fa-ce	financiación	directa	capacidad de financiar activos con fondos propios, por lo que si el ratio aumenta, significa que la compañía financia sus activos fijos con fondos que disminuyen la probabilidad de quiebra
proporción agregada	f_td-ta	financiación	inversa	a mayor deuda más posibilidades de incumplimiento
financiación por dividendos	f_dp-e	financiación	directa	capacidad de remunerar fondos propios supone buena salud financiera
valor de mercado de la empresa v/s valor contable de la deuda	f_mve-tl	financiación	directa	la relación inversa entre la valoración de la compañía a precios de mercado y la de la deuda es una medida de confianza de los inversionistas en la compañía
porción fuentes externas	f_td-ce	financiación	inversa	si la proporción de endeudamiento crece demasiado la posibilidad de impago aumenta
cobertura de capital de trabajo	l_s-wc	liquidez	inversa	El aumento de la cobertura del capital de trabajo aumenta el riesgo de impago por falta de recursos líquidos
financiamiento de largo plazo	l_wc-ltd	liquidez	directa	A mayor capital de trabajo neto respecto de la deuda de largo plazo menor es la posibilidad de no pagar las obligaciones
proporción de inversiones de corto plazo	l_wc-ta	liquidez	directa	indica la proporción de capital de trabajo invertido respecto del total de activos
porción de deuda corriente sobre los activos	l_cl-ta	liquidez	inversa	indica la proporción de deuda a corto plazo respecto del total de activos, por lo que su aumento eleva el riesgo de crédito
necesidad de efectivo	l_quick	liquidez	directa	indica la proporción de recursos líquidos que tiene la compañía para pagar las deudas de corto plazo, por lo que el aumento del ratio disminuye el riesgo de impago
proporción de inversiones	l_cas-ta	liquidez	directa	indica la proporción de recursos líquidos, descontado el inventario, respecto del tamaño de la compañía, por lo que el aumento del ratio disminuye el riesgo de impago

(continúa en la siguiente página)

(continuación de la página anterior)

Variable	nombre	concepto	relación	motivo que respalda la interpretación financiera
necesidad de efectivo de mediano plazo	l_cas-cl	liquidez	directa	es la proporción de recursos líquidos para cubrir las deudas sin contar con la liquidación de stock, por lo que una disminución de la ratio aumenta el riesgo de crédito
capital de trabajo	l_ca-cl	liquidez	directa	es la proporción de recursos líquidos para cubrir las deudas, por lo que una disminución de la ratio aumenta el riesgo de crédito
necesidad de efectivo de corto plazo	l_c-cl	liquidez	directa	es la proporción de efectivo para cubrir las deudas, por lo que una disminución de la ratio aumenta el riesgo de crédito
nivel de stocks	l_i-tca	liquidez	inversa	indica la proporción de inventario invertido respecto del total de activos, por lo que su aumento incrementa la posibilidad de impago (ceteris paribus con los otros componentes del activo circulante).
proporción de inversiones corrientes	l_ca-ta	liquidez	directa	indica la proporción de recursos líquidos respecto del tamaño de la compañía, por lo que el aumento del ratio disminuye el riesgo de impago
proporción de deuda corriente	l_cl-tl	liquidez	directa	indica la proporción de deuda a corto plazo respecto del total de deuda, por lo que su aumento eleva el riesgo de crédito
cobertura de intereses	g_ebit-i	rentabilidad	directa	indica que las utilidades del negocio permiten pagar el servicio de la deuda, por lo que cuando el ratio aumenta, la posibilidad de impago disminuye
rentabilidad sobre inversión	g_nia-ta	rentabilidad	directa	indica que las utilidades del negocio permiten continuar las operaciones, por lo que cuando el ratio aumenta, la posibilidad de impago disminuye
rentabilidad comercial	g_ebit-s	rentabilidad	directa	indica que las utilidades del negocio permiten continuar las operaciones, por lo que cuando el ratio aumenta, la posibilidad de impago disminuye
rentabilidad sobre infraestructura	g_ronfa	rentabilidad	directa	indica que las utilidades del negocio permiten continuar las operaciones, por lo que cuando el ratio aumenta, la posibilidad de impago disminuye
rentabilidad sobre inversión	g_ebit-a	rentabilidad	directa	indica que las utilidades del negocio permiten continuar las operaciones, por lo que cuando el ratio aumenta, la posibilidad de impago disminuye
rentabilidad sobre patrimonio	g_roe	rentabilidad	directa	indica que las utilidades del negocio permiten continuar las operaciones, por lo que cuando el ratio aumenta, la posibilidad de impago disminuye
capacidad de autofinanciamiento	g_re-ta	rentabilidad	directa	indica que las utilidades del negocio permiten continuar las operaciones, por lo que cuando el ratio aumenta, la posibilidad de impago disminuye
Indicador de volatilidad bursátil	v_vol250	volatilidad	inversa	la variable está relacionada con la incertidumbre que el mercado percibe sobre la cotización bursátil de las acciones de la compañía. La fuente de esta incertidumbre puede provenir de fuentes directas de la compañía (problemas comerciales, problemas financieros o de gestión) como de fuentes externas a la empresa (niveles de precios de la bolsa, inflación, etc.), por lo que es posible que esta variable sea un buen sensor de la calidad crediticia y de su probabilidad de impago, pero puede estar contaminada por otros elementos exógenos al riesgo de crédito.

Fuente: elaboración propia

2.6 Resumen

En este capítulo se expone una revisión histórica y conceptual de las distintas aproximaciones que se usan para medir el riesgo de crédito, tanto aquellos usados por inversionistas institucionales, la banca y propuestas que provienen desde la academia. Se ha entregado en este capítulo una visión general y panorámica de los modelos usados para medición del riesgo crediticio. Respecto de los modelos de carteras de activos, se han revisado los modelos estructurales y de forma reducida, que han sido propuestos desde el mundo académico, y se han expuesto los modelos que han sido patrocinados por instituciones financieras, con la finalidad de revisar la importancia y utilidad de las calificaciones de crédito que conceden las agencias de rating. También se han revisado las aproximaciones de medición de riesgo crediticio individuales, usados principalmente para la concesión de créditos bancarios y para la evaluación individual de inversiones en títulos de renta fija. No obstante lo anterior, se ha realizado una mayor exposición de los estudios realizados en el ámbito de la réplica de rating, debido al especial interés de esta tesis.

Se han dejado evidencias acerca de la importancia relativa del uso de rating. Sin embargo, cabe resaltar que la emisión de rating es costosa y, por lo tanto, su réplica con sistemas automáticos y técnicas cuantitativas presenta ventajas económicas. Debido a su relativo fácil cálculo y a que su potencial uso es amplio (directamente o como insumo de datos para modelos de medición de riesgo en carteras), la réplica de ratings es, por tanto, un área de investigación interesante. Entonces, la réplica de rating es especialmente atractiva cuando pudiese utilizarse como sustituto del original, es decir, cuando la compañía o instrumento de deuda no tiene calificación crediticia. Cabe recordar que el número de empresas que posee rating es muy reducido.

Luego de concluir la revisión de investigaciones realizadas de la réplica de rating, el autor de esta tesis ha expuesto las tareas necesarias para realizar dicha réplica. Para realizar esta tarea de réplica de ratings el autor de esta tesis ha expuesto:

- qué tipo de rating recomienda se utilice,
- qué tipo de datos son necesarios para realizar la réplica,
- qué granularidad o número de clases recomienda replicar, y
- cuáles han sido las técnicas utilizadas para realizar esta réplica.

Se ha intentado cubrir cada uno de estos puntos en este capítulo, a excepción del último. La revisión de técnicas estadísticas y de Inteligencia Artificial que pueden usarse en la réplica de ratings es expuesta en el siguiente capítulo.

Capítulo 3. Técnicas usadas en Riesgo de Crédito

En la evaluación del riesgo crediticio se ha empleado un gran número de técnicas. En particular, para la concesión de crédito y para la réplica de rating, se han utilizado técnicas que tienen por finalidad dos tareas: (i) describir las características financieras de un deudor para encontrar una explicación de su calidad crediticia y (ii) predecir cuál será el comportamiento de un potencial deudor frente al pago de sus obligaciones. No obstante, no existe una única teoría comúnmente aceptada que establezca qué variables financieras ni cuál es su importancia relativa para determinar la futura calidad crediticia del deudor. Por ello, muchas investigaciones suelen basarse en reglas heurísticas. La construcción de este análisis heurístico se ha implementado tradicionalmente a través de la aplicación de técnicas estadísticas. Sin embargo, estas técnicas presentan limitaciones, debido a los supuestos sobre los que se basan y a la propia naturaleza de la información financiera. Por ello, resulta muy útil el uso de técnicas de Inteligencia Artificial, ya que en la mayoría de los casos superan estas limitaciones. La flexibilidad de las técnicas de IA es un importante atractivo para encontrar soluciones a problemas de tipo crediticio.

En este capítulo se presentan las técnicas más utilizadas para el análisis de riesgo crediticio con fines predictivos; en particular, aquellas que sirven para la tarea de réplica de rating, haciendo énfasis en las de IA. En la mayoría de las investigaciones de réplica de rating existen, explícita o implícitamente, procedimientos o pasos comunes; a saber:

- (a) la transformación o manipulación de las variables con la finalidad de aumentar la eficiencia de la predicción o para cumplir supuestos del modelo,
- (b) la selección del conjunto de datos y de una técnica de validación que permita mejorar las predicciones y extrapolaciones,
- (c) la elección de una o más técnicas predictivas, y
- (d) la cuantificación de la bondad de la predicción.

Cada uno de estos pasos usualmente apunta a aumentar el nivel de aciertos de la predicción fuera del conjunto de datos. Además, existe un fuerte vínculo entre los cuatro pasos, de tal forma que la decisión en algunos de los tres primeros pasos condiciona la bondad de la precisión y, en ocasiones, algunos de los restantes pasos. Por ejemplo, la elección de una determinada técnica de predicción puede influir en la selección del conjunto de datos, en la técnica de validación que utiliza el investigador y en el porcentaje de aciertos. Esta interdependencia no es la misma en todos los casos e influye la finalidad que pretenda el investigador y el conjunto de supuestos del modelo elegido. El orden de presentación

de este capítulo respeta estos cuatro pasos comunes llevados a cabo en las investigaciones de predicción de riesgo crediticio, con el objetivo de presentar aquellas técnicas útiles para replicar el rating externo. Luego se analizan los resultados obtenidos en los trabajos empíricos revisados en esta memoria que se han aplicado a la réplica de ratings.

3.1 Transformación de las variables

Para predecir el fenómeno del riesgo de crédito, algunos investigadores han propuesto la transformación de variables explicativas (atributos de las compañías) desde su forma original (Pinches y Mingo, 1973; Flagg y Giroux, 1991; Dougherty, Kohavi y Sahami, 1995; Neophytou y Mar, 2003, entre otros). Las siguientes transformaciones son las más usadas en este campo de análisis económico: (a) la transformación con alguna función biyectiva, (b) la discretización y (c) el cambio de dimensionalidad de las variables. Todas estas transformaciones buscan aumentar el poder predictivo.

3.1.1 La transformación de las variables con una función

Cuando una variable no satisface las condiciones del modelo planteado suele usarse una función biyectiva que pueda corregir la deficiencia, distinguiéndose dos categorías: la transformación lineal y la no lineal. La transformación lineal más habitual es la normalización.

Por otra parte, las transformaciones no lineales cambian la distribución de datos para satisfacer las condiciones del modelo que se desea usar. Usualmente se busca ajustar la distribución de datos a la normal y estabilizar su varianza. Para ello se suele usar la transformación logarítmica, la raíz cuadrada y la inversa. Este tipo de transformaciones suele justificarse porque algunas técnicas estadísticas se han construido sobre la suposición de que las variables independientes siguen una distribución normal y se modelan homocedásticamente. En la medida que estas suposiciones se incumplen, entonces la capacidad para clasificar y predecir correctamente disminuye.

De todas aquellas variables que se han usado en la literatura financiera, la transformación más frecuente es aquella que normaliza variables de tamaño (ventas, total de activos, entre los más usados). Por ejemplo, para la predicción de quiebras Flagg y Giroux (1991) aplican el logaritmo al total de activos corporativos. Frydman et al. (1985) transforman logarítmicamente la cobertura de intereses y el total de activos. Para la predicción de rating de agencias también se han usado estas transformaciones. Pinches y Mingo (1973) utilizan inicialmente 35 variables para construir un modelo que permita replicar rating en 5 clases, y de todas ellas, calcular el logaritmo en 13 de ellas y a otras 15 variables se le calculan normalizaciones para su rango, acotando los valores de la variable a no más de 2 veces su desviación estándar sobre su media.

3.1.2 Discretización de variables continuas

La discretización es otro tipo de transformación que consiste en la conversión de los valores de una variable numérica en valores nominales ordenados, a través de la agrupación de los distintos valores de la variable. La tarea de discretización se lleva a cabo cuando (1) el error en la medida puede resultar muy grande; (2) cuando existen umbrales significativos; (3) cuando la aplicación de rangos tiene diferentes criterios de interpretación; (4) cuando se desea integrar diferentes escalas; (5) cuando la discretización disminuye los costes de cálculo computacional o mejora la interpretación de los resultados; o (6) cuando se desea utilizar conjuntamente variables nominales y numéricas.

Un caso de discretización que habitual e inconscientemente hacen los analistas financieros ocurre cuando deben diferenciar una compañía de gran tamaño versus una de pequeño tamaño (Andersson, 2001). Algo similar ocurre cuando la interpretación de las características de las empresas difiere mucho porque los valores de las variables que las caracterizan se encuentran en zonas de rangos críticos. Por ejemplo, la interpretación del cambio de valor de una ratio puede ser muy distinta cuando está en torno a -0,9 que cuando lo hace en torno a 0,1.

Otro argumento por el cual se puede aconsejar la discretización se debe a la disminución del coste de cálculo, el coste computacional de los sistemas de aprendizaje, o por la fácil interpretación de los resultados (Liu, Hussain y Tan, 2002; Dougherty, Kohavi y Sahami, 1995). De hecho, los expertos financieros intuitivamente suelen discretizar los datos métricos, de tal manera que la inferencia les sea más fácil. Siguiendo a Andersson (2001), los expertos financieros que evalúan la situación crediticia de terceros interpretan la información separándola en categorías. Para obtener un juicio, los expertos suelen aplicar diversas estrategias o algoritmos cognitivos que indican un criterio de orden o jerarquización y un criterio de compensación.

Para realizar la tarea de discretización se pueden utilizar diversos métodos. Una separación de los tipos de discretización es considerar procesos supervisados versus aquellos que no lo son. Los métodos no supervisados no tienen en cuenta la clase a la que pertenecen las variables explicativas, siendo los métodos más simples el de intervalos de igual anchura y el de intervalos de igual frecuencia (Dougherty, Kohavi y Sahami, 1995). El primero de estos dos métodos divide en k intervalos (el valor k es sugerido por el usuario a su propia conveniencia o evidencia empírica) la distancia entre el máximo y el mínimo valor (simple binning). En cambio, el método de intervalos de igual frecuencia divide el rango de la variable en k intervalos de modo que en cada uno de ellos haya un mismo número de datos empíricos. Por otra parte, los métodos supervisados, consideran la interdependencia entre la variable que se desea discretizar y la clase a la que pertenecen los patrones. Siguiendo a Ruiz, Angulo y Agell (2005), algunos métodos de esta categoría están basados en medidas de separabilidad (Catlett,

1991; Fayyad e Irani, 1993), mientras que otros utilizan procedimientos estadísticos y métodos que aprovechan la información mutua entre la variable explicativa (o independiente) y la clase (Kurgan y Cios, 2001). Debido a la reciente definición de este tipo de técnicas, las aplicaciones de la discretización en el campo financiero son muy escasas, y más aun en el análisis de riesgo crediticio. Hasta la fecha, aplicaciones como la de Rovira, Agell, Sánchez et al. (2004) son pioneras en este ámbito.

Un tipo específico de métodos de discretización supervisada se basa en la relación de dependencia entre la clase y los atributos. Uno de los coeficientes propuestos para medir dicha relación es el CAIR, de Class-Attribute Interdependence Redundancy (Ching, Wong y Chan, 1995). El método CADD (Class-Attribute Dependence Discretizer) usa esta relación para decidir la mejor partición. Para obtener la relación CAIR se debe calcular la probabilidad conjunta y marginal de encontrar un patrón por cada clase de acuerdo a su frecuencia relativa. En cambio, el método CAIM busca maximizar la relación de dependencia clase-atributo y minimizar el número de subintervalos. Una modificación a este CAIM ha sido propuesta en Ruiz, Angulo y Agell (2005) y en Ruiz (2006). A esta propuesta le llama método CAIM*. Aplicaciones del método CAIM en el ámbito de réplica de rating se encuentran en Campos, Ruiz, Agell y Angulo (2004) y Ruiz et al. (2005).

Por último, es importante señalar que, en la mayoría de los casos en que se ha usado una técnica de discretización, ésta ha significado una pérdida de información, que se refleja en mayores tasas de error (Dacunha-Castelle y Florens-Zmirou, 1986; Ruiz et al., 2005). Como se pierden los valores originales, el proceso de discretización supone la pérdida de una parte de la información contenida en los datos fuente. La discretización implica que se pierde el detalle, pero se gana la posibilidad de observar la generalización de los datos. Se sacrifica por la simplificación producida y por la mayor facilidad en la interpretación de los resultados. Pero esto no ocurre siempre, ya que un método de discretización de igual anchura, intuitivamente debería presentar una debilidad cuando las observaciones no se distribuyan uniformemente (Kotsiantis y Kanellopoulos, 2006). Por lo tanto, un buen algoritmo de la discretización tiene que balancear la pérdida de la información con la ganancia de generalización, al generar un número razonable de puntos de corte.

3.1.3 Cambio de dimensionalidad

La alta dimensionalidad puede ser un problema para algunas técnicas de estimación y sistemas de aprendizaje. Es decir, si existen muchas dimensiones en el modelo (variables que reflejan una característica de una compañía), el aprendizaje o proceso de ajuste puede ser poco robusto o fiable (Hernández, Ramírez y Ferri, 2004). Por lo tanto, para aumentar el grado de fiabilidad en algunos estudios se ha optado por reducir la dimensionalidad a través de la transformación del conjunto de variables, evitando en la medida de lo posible la pérdida de información relevante que se puede

producir por la eliminación de variables del conjunto de datos. La información que los datos contienen se transforma en un conjunto de nuevos atributos o variables, reduciendo su número. Las técnicas más conocidas para reducir dimensionalidad son el Análisis de Componentes Principales y el Análisis Factorial (Hair, Anderson, Tatham y Black, 1999). Otras técnicas lineales son el Análisis de Componentes Independientes y la Descomposición de Valores Singulares (Lee y Verleysen, 2007). Sin embargo, estas técnicas capturan sólo las relaciones lineales entre las variables, y cuando existe una relación no lineal entre ellas, no pueden capturarla eficientemente. Por ello, las propuestas basadas en algunas redes neuronales que capturan estas relaciones no lineales, como los mapas auto-organizados (Kohonen, 1989) o el escalado multidimensional (Neophytou y Mar, 2003) pueden ser respuestas más adecuadas para este tipo de problemas de alta dimensionalidad. De acuerdo a Belkin (2003) algunos algoritmos proponen tomar ventaja de las potenciales estructuras múltiples de los datos; por ejemplo, la técnica de Isomap de Tenenbaum, de Silva y Langford (2000) intenta preservar las distancias entre los datos contiguos o vecinos, una vez que se ha disminuido la dimensionalidad. En el ámbito financiero Neophytou y Mar (2003) utilizan el escalado multidimensional para predecir el fallido de compañías en el Reino Unido.

3.2 El conjunto de datos y las técnicas de validación

Una vez que se ha elegido el adecuado conjunto de variables y se han transformado aquellas que se ha considerado necesario, los siguientes pasos son (1) la selección de los subconjuntos de datos que servirán para el proceso de aprendizaje o estimación de los estadísticos y (2) la selección de la técnica de validación de los resultados.

Precisamente, en problemas de clasificación y predicción de riesgo crediticio los conjuntos de datos utilizados no suelen ser aleatorios debido a que los autores se encuentran restringidos por el número total de datos. Por ejemplo, el número total de empresas que tienen calificación crediticia y de las cuales se puede obtener información de su condición financiera y características corporativas es muy bajo. Por ello, los investigadores comúnmente toman en consideración algunas características de las empresas respecto del total de la población, de tal manera que el conjunto de datos sea más homogéneo. El sector industrial, el tamaño de la empresa y su edad son los factores que más se repiten en la literatura financiera cuando se evalúan factores externos que permitan separar grupos de compañías y realizar tareas de clasificación y predicción (Arvanitis y Gregory, 2001; Glasserman y Li, 2004).

Una vez seleccionado el conjunto de datos que se utilizará en la investigación, es conveniente separar subconjuntos destinados al ajuste de los parámetros del modelo y a la validación de los resultados. Es decir, desde la totalidad de datos se seleccionan, al menos, dos subconjuntos de datos. Uno de ellos,

llamado subconjunto de entrenamiento, permite el cálculo de estimadores que mejor ajusten la función de la técnica de predicción o aprendizaje. El segundo subconjunto de datos se usa para las pruebas o test de precisión, si se trata de validación simple (Moore y McCabe, 2005). Otra alternativa es dividir el conjunto de datos en 3 porciones. Además del subconjunto de entrenamiento, la tercera porción de datos se usa para hacer las pruebas finales (a veces denominadas pruebas fuera de la muestra). Ya sea que el conjunto de datos se divida en dos o en tres partes, la prueba realizada sobre el grupo de datos que no se han usado para el entrenamiento y ajuste suele denominarse prueba *holdout* (Myers y Forgy, 1963; Kohavi, 1995). De la revisión de estudios de réplica de rating de compañías y bonos corporativos el 75% de ellos utilizó holdout.

Respecto del tamaño de los conjuntos de datos, los trabajos de investigación en riesgo crediticio suelen incluir bases de datos pequeñas (ver la Tabla 23, en la página 91); especialmente si estos conjuntos de datos son comparados con aquellos utilizados en otras disciplinas científicas como la Ingeniería o la Química. Por ello, los estudios de las últimas décadas suelen desechar la validación simple (que usa los dos conjuntos de datos separadamente) y han optado por usar la validación cruzada o el bootstrapping (Stone, 1974; Kohavi, 1995). De hecho, la validación cruzada es el diseño experimental más utilizado entre los investigadores en aprendizaje automático y otras disciplinas en los últimos años. En la revisión de esta tesis, del total de artículos de réplica de rating el 25% de ellos usan validación cruzada y todas ellas son realizadas desde los años noventa (ver Tabla 15). Existen distintas variantes de validación cruzada, aunque la más utilizada es la de k -carpetas (k -fold cross validation), la que consiste en dividir aleatoriamente (estratificadamente o no) el conjunto de casos disponibles en k subconjuntos disjuntos de igual tamaño, T_1, \dots, T_k . Se realizan k experimentos usando como subconjunto de entrenamiento $U_{j \neq i}$, formado por todas las carpetas restantes, en la iteración i , y como subconjunto de prueba T_i . Cada iteración da lugar a una muestra de k estimaciones del error y de los estadísticos, los cuales se promedian para considerar los resultados finales del proceso.

Otras técnicas de validación cruzada utilizan todas las posibles particiones con un tamaño de conjunto dado (complete cross validation). Un caso extremo de este tipo de diseño de experimento es leave-one-out (1-o-o), también conocido como método U (Lachenbruch y Mickey, 1968; Geisser, 1975). Al usar leave-one-out cada conjunto de prueba contiene un único caso y existen n experimentos, siendo n el tamaño de la muestra. Se entrena o ajusta el modelo con $n-1$ casos y se valida con el n -ésimo caso. El proceso termina cuando se ha realizado la validación o test con todos los casos y se promedian los niveles de aciertos, los errores y los estadísticos.

La mayor ventaja de la validación cruzada con k carpetas es que las estimaciones del error sobre los subconjuntos de test son independientes (ya que no se solapan directamente). Sin embargo, existen complicaciones para este tipo de validación cuando: (i) se produce solapamiento de las carpetas en el

conjunto de datos de entrenamiento y (ii) si existe un desequilibrio entre el número de ejemplos utilizados para el test y el entrenamiento (especialmente cuando $k > 3$). De acuerdo con Bradford y Brodley (2001), esto causaría sobreajuste en el modelo y la estimación del error tendría mayor variabilidad. Sobreajuste significa que los estadísticos del modelo se ajustan extremadamente bien al conjunto específico de datos (con un error muy bajo), pero causan un error demasiado grande cuando dicho modelo se aplica a datos que están fuera del conjunto que se usó para ajustar el modelo. Para solucionar estos problemas Diamantidis, Karlis y Giakoumakis (2000) proponen una estrategia que particiona los conjuntos de casos, de tal manera que cada subconjunto contenga casos lo más diversos posibles y sea lo más similar a los restantes subconjuntos o particiones.

3.3 Elección de las técnicas predictivas

Una vez que se han seleccionado adecuadamente el conjunto de datos, las variables y la forma como se realizará el proceso de validación, corresponde elegir una o más técnicas que permitieren realizar la predicción o réplica. La Tabla 17 muestra un conjunto de artículos de predicción del riesgo crediticio individual, exhibiendo qué técnica han usado para realizar la predicción. Actualmente existe un gran número de técnicas predictivas y clasificatorias. Bajo esta sección del capítulo se presenta una revisión de las principales técnicas que se han utilizado en el ámbito predictivo del riesgo de crédito de compañías, haciendo hincapié en aquellas clasificatorias que están relacionadas con el tema central de esta tesis: la réplica de rating crediticio.

Tabla 17. Artículos de predicción del riesgo crediticio individual con diferentes técnicas cuantitativas.

Referencia	Técnicas Estadísticas				Técnicas de Inteligencia Artificial					
	AD	PL	P	RL	RN	DT	SVM	IBL	AG†	FL†
Kaplan y Urwitz (1979)		*	*							
Fryedman et al. (1985)	*					**				
Dutta y Shekhar (1988)				*	**					
Utans y Moody (1991)				*	**					
Tam y Kiang (1992)					**	*		*		
Han y Jhee (1993)	*				**					
Kim et al. (1993)	*	*		*	*			**		
Back et al. (1996)	*			*						**
Maher y Sen (1997)		*			**					
Kwon et al. (1997)	*				**					
Chaveesuk et al. (1999)		*		*	**			*		
West (2000)				**		*		*		
Galindo y Tamayo (2000)			*		*	**		*		
Fan y Palaniswami (2000)	*				*		**	*		
Shin y Han (2001)	*				*	*			**	
Baesens et al. (2003)				**	*	*	*	*		
Campos et al. (2004)	**						*			
Huang et al. (2004)				*	*		**			
Härdle et al. (2005)	*						**			
Rovira et al. (2005)	*			**			*			
Kou, Peng, et al.(2006) †	*					*	**			
Ravi, Kurniawan et al.(2008)					**	*	*			
Lee (2007)	*				*		**			
Ahn y Kim (2011)					*		**			
Wang y Ma (2011)				*	**	*				
Öğüt, Goğanay et al.(2012)	**			*	*		**			

Notas: (†) En Kou, Peng, et al. (2006) se han usado distintas bases de datos, y aquí sólo se han mostrado los resultados de la base de datos alemana, que no difiere sustantivamente de las restantes. La identificación con un asterisco (*) indica que ha sido usada dicha técnica, y dos asteriscos (**) indica que ha sido la mejor técnica usada en dicho estudio. Las predicciones en cursiva tanto de algoritmos genéticos (AG†) y Fuzzy Logic (FL†), en realidad son híbridos con redes neuronales (RN). Lo mismo sucede con el modelo Instance-Based Learning (IBL) usado por Kim, Weistroffer y Redmond (1993). Otras abreviaciones son análisis discriminante (AD), modelo de probabilidad lineal (PL); probit (P); es regresión logística (RL); Árboles de decisión (DT) y Support Vector Machines (SVM).

Fuente: Elaboración propia.

De todas las técnicas predictivas es usual encontrar dos tipos: las de clasificación y las de regresión. En la tarea de clasificación el objetivo es predecir la clase a la que pertenecen nuevos casos con el mayor grado de precisión. La regresión, en cambio, consiste en aprender (ajustar) una función real que asigne a cada evento o caso un valor real. En el contexto de esta tesis, ambos tipos de técnicas buscan distinguir características del deudor y, desde esta caracterización, asignarle un valor del riesgo equivalente con la mayor precisión posible. Esta tarea se puede realizar con dos conjuntos de técnicas ampliamente utilizadas: las estadísticas y las de IA. Tal y como se puede observar en la Tabla 17 y en la Tabla 19, las técnicas estadísticas más usadas para la réplica de rating son análisis discriminante (Fisher, 1936; Durand, 1941; Hair et al., 1999) y regresión logística (Press y Wilson, 1978; Hosmer & Lemeshow, 2000). En este capítulo se concentra la atención en las técnicas basadas en IA, debido a dos importantes atractivos para la réplica de ratings:

- i) las técnicas de IA suelen aproximarse a la solución de los problemas de una manera distinta a la realizada por técnicas estadísticas convencionales: lo hacen de una manera *inteligente*, es decir,

resuelven los problemas imitando los procesos de aprendizaje presentes en la naturaleza (tanto de la biología humana como desde los procesos evolutivos de selección natural de las especies y poblaciones), y por ello, surge el segundo atractivo,

- ii) las técnicas de IA resuelven los problemas sin incluir suposiciones restrictivas al fenómeno observado, con lo cual, muchos supuestos estadísticos no son necesarios. Con ello, se puede mejorar la calidad de los resultados y de su extrapolación a otros conjuntos de datos.

Por último, antes de especificar cada una de estas técnicas, es necesaria una aclaración importante: esta división entre técnicas estadísticas y de IA no tiene un límite claramente definido. Es más, muchas técnicas de IA aprovechan avances logrados en la Teoría Estadística, confundiendo más aún la frontera entre ambas técnicas - si es que ésta existe.

3.3.1 Sistemas de Aprendizaje Automático

En IA los sistemas de aprendizaje contemplan dos vías para resolver problemas de predicción: de una manera supervisada o de una manera no supervisada. Cuando se trata de la primera de ellas, existen parejas de patrones entrada-salida que el sistema automático aprende y asocia. En el segundo tipo de aprendizaje, el no supervisado, sólo existen datos de entrada para que el sistema de aprendizaje extraiga los rasgos característicos o esenciales (Hastie, Tibshirani y Friedman, 2001; Hernández et al., 2004; Russell y Norvig, 2003).

En problemas de riesgo crediticio, las técnicas que más se han utilizado y han tenido éxito, son los Sistemas de Aprendizaje Automático (SAA). Este tipo de sistemas de aprendizaje ha sido ampliamente utilizado debido a que su eficiencia obtenida ha contribuido a mejorar las predicciones. Aun más, Wong, Lai y Lan (2000) revisan artículos publicados en revistas científicas entre 1984 y 1998, y manifiestan que luego de un auge por el uso de redes neuronales, como un tipo particular de SAA, hacia problemas financieros en general (y de inversión en bolsa, en particular), el interés por estas aplicaciones ha disminuido, pero la predicción de quiebras con este tipo de técnicas es una área de investigación que no ha cesado. Uno de los motivos que ha generado este elevado interés, es que los SAA admiten complejas relaciones entre los datos, asumiendo subyacentemente que las variables de entrada les permiten a estas técnicas aprender y reconocer patrones para clasificar o predecir un indicador de su calidad crediticia futura, sin que se impongan supuestos externos a los datos.

A continuación se exponen los SAA de mayor uso en la predicción y clasificación crediticia. Las técnicas a describir serán las redes neuronales, algunas técnicas de Soft Computing, los Árboles de Decisión, los Sistemas Automáticos de Soporte Vectorial y los Métodos Basados en Vecindad. Estas tres últimas técnicas son especialmente utilizadas para tareas de clasificación ya que son algoritmos

que maximizan las diferencias grupales o minimizan las distancias intragrupalas. En cambio, las redes neuronales son sistemas de aprendizaje que buscan una solución a través de la interconexión de múltiples procesos secuenciales, y las técnicas de Soft Computing resuelven problemas tomando en cuenta la capacidad de adaptación frente a entornos cambiantes. Una de las más importantes similitudes entre todas estas SAA es que todas ellas realizan el proceso de aprendizaje sin la necesidad de aplicar supuestos al modelo. Respecto de las variables que alimentan el aprendizaje, tampoco necesitan de restricciones y la forma que tiene la salida de información para las técnicas de clasificación es la misma: variables discretas, aunque algunas de ellas permiten como salida la probabilidad de ocurrencia. Un resumen comparativo de los input y output de los modelos se presenta al final de esta sección (ver Tabla 19).

3.3.1.1 Redes Neuronales

Las redes neuronales (RN) son sistemas automáticos de aprendizaje formados por unidades de procesamiento interconectadas a través de enlaces, donde cada unidad de procesamiento (la neurona) calcula una función lógica, con entradas y pesos sinápticos que determinan la influencia de cada entrada en la activación de la neurona (Escolano, Cazorla, Alfonso, Colomina y Lozano, 2003). El objetivo de cada RN es aprender automáticamente las propiedades deseadas del fenómeno estudiado o del problema a resolver. Una de las premisas y motivaciones iniciales de estos sistemas de aprendizaje ha sido la capacidad de emular a sus procesadores biológicos homólogos: las neuronas orgánicas. Debido a esta imitación, es comúnmente deseable que las redes neuronales (a) sean robustas en el procesamiento de información y tolerantes a fallos (aprendiendo a solucionar problemas, omitiendo aquellos que sean irrelevantes), (b) sean flexibles frente a cambios del entorno o situaciones, y (c) sean capaces de trabajar con información incompleta, inconsistente o con ruido (Hernández et al., 2004). En una RN las salidas de algunos nodos se conectan con las entradas de otros nodos, de tal manera que las neuronas de la primera capa se combinan según un juego de ponderaciones w y alimentan a la próxima capa. Durante la fase de entrenamiento, los datos alimentan de información a la red y los pesos se modifican para minimizar las tasas de error del vector de salida y . La modificación de los pesos puede hacerse cuando la activación de las neuronas es transmitida por la red (la propagación hacia delante) o bien cuando la red se organiza a partir de la transferencia de información más reciente (el aprendizaje)¹². El aprendizaje de una RN puede ser supervisado o no-supervisado. En este último caso, la red debe auto-organizarse para aprender del conjunto de datos existentes, y es más útil para tareas de agrupamiento y reducción de dimensionalidad. En cambio, el aprendizaje supervisado es más apropiado para tareas de regresión y clasificación. Por ello, la mayoría de las técnicas de RN utilizadas para tareas de predicción en riesgo crediticio son de tipo supervisado (Dutta y Shekhar, 1988; Kim et al., 1993; West, 2000; Wang y Ma, 2011).

¹² Diversos autores exponen esta configuración de una manera más detallada. Recomendamos diversas lecturas en caso de profundizar (Haykin, 1999; Buhmann, 2003; Hernández et al., 2004)

Particularmente, para las redes neuronales supervisadas los nodos de entrada reciben los valores de los datos y los transmiten a través de la red neuronal, para comparar las salidas con los valores reales. Un nodo de entrada representa una única variable. Las variables métricas independientes sólo requieren un nodo por variable, mientras que las no-métricas tienen que estar codificadas a través de variables ficticias (dummy). Un nodo de salida entrega el valor final que, en el caso clasificatorio, es un valor discreto definido previamente (por ejemplo, un rating representado numéricamente). Estos son los únicos requerimientos de una RN, ya que no necesita de supuestos distribucionales, de independencia de los parámetros o de algunas características especiales de las relaciones entre las variables (Hernández et al., 2004; Haykyn, 1999; Buhmann, 2003).

Una de las primeras RN que se emplearon fue el Perceptrón simple (Rosenblatt, 1962). Su arquitectura (configuración de la estructura y las relaciones entre los nodos) tiene varios nodos de entrada y uno o más de salida dicotómica, no tiene capa oculta y tiene un umbral θ . Otra RN similar a esta arquitectura es Adaline (Widrow y Hoff, 1960), que no tiene capa oculta, pero difiere del perceptrón simple en que se puede usar con neuronas binarias o continuas (cuya salida es real). A pesar de los buenos resultados obtenidos con estos dos tipos de RN, éstas adolecen de un problema: cuando los datos no sean linealmente separables la RN puede no entregar una solución. Este problema queda resuelto con el uso de una red perceptrón multicapa, que fue difundida en la década de los ochenta por el grupo Paralel Distributed Processing con el nombre de red Retropropagación o Backpropagation. En este tipo de algoritmo, la activación se propaga a través de los pesos desde la capa de entrada hacia la(s) capa(s) intermedia(s), donde se aplica una función de activación a las entradas. Luego, el ajuste de las tasas de error se aplica desde las capas de salida hacia las de entrada. Debido a esta mejora, las redes neuronales comenzaron a ser utilizadas en mayor número en investigaciones académicas y en la práctica financiera. Este es el caso de Tam y Kiang (1992), quienes aplican una RN Retropropagación (RNRP) para predecir la quiebra bancaria y comparan los resultados con otras técnicas predictivas. Wilson et al. (1995) utilizan 112 compañías inglesas (entre 1972 y 1979) para comparar las predicciones categóricas de 3 estados de la calidad crediticia de compañías con un modelo logit y una RNRP, dejando en evidencia que esta última modelación fue en promedio un 15.2% más eficiente que el logit. Aun más, de las publicaciones recopiladas por Wong et al. (2000) acerca de problemas de riesgo de crédito y aplicadas con RN, el 56% eran RNRP, y de las recopiladas por Adya y Collopy (1998), el 94% de las investigaciones usaron RNRP.

Otro tipo de RN desarrollada para tareas predictivas o clasificatorias es la Función de Base Radial, en adelante RBF, debido a sus siglas de Radial Basis Function (Moody y Darken, 1989). Su característica más importante es el uso de una función de cálculo (y no de activación, como en las RNRP) en las neuronas de la capa oculta (funciones base). Así, transforman de una manera no-lineal las variables

desde el espacio de entrada al de la capa intermedia. Una RBF calcula la proximidad de la entrada x a un vector de parámetro s -dimensional (μ_h), asociado con la neurona oculta h , donde la distancia euclídea normalizada, desde el centro μ_h , se usa como un argumento en una función núcleo, que se asume positiva, radialmente simétrica con un único máximo en su centro μ_h , y desciende rápidamente hacia cero si está lejos del centro (Haykin, 1999). Para predicción de riesgo de crédito comenzaron a aplicarse RBF desde los años noventa (Kim et al., 1993; Rovira et al., 2004).

Dentro de las RN no supervisadas, aquellas vinculadas a métodos de aprendizaje competitivo han sido utilizadas en algunas oportunidades para ayudar al proceso de clasificación de compañías o solicitantes de crédito, analizando sus características financieras y de su posición competitiva. Estos tipos particulares de métodos, también conocidos como tareas de clustering, se utilizan principalmente para agrupar conjuntos de datos, ya que la red se auto-organiza en base a la estructura existente en el conjunto de datos de entrada, aunque se proporciona una respuesta correcta o errónea a la red (ya que no es supervisada). Adaptive Resonance Theory (ART) y Mapas auto-organizados (Self-Organizing Maps o SOM) son las variantes más importantes de aprendizaje competitivo. Estas dos arquitecturas han sido utilizadas en problemas de riesgo de crédito para extraer características de los datos de compañías y no para clasificar. Martín del Brío y Serrano-Cinca (1993) proponen un modelo híbrido que combina SOM con otros modelos estadísticos para obtener una puntuación o score. Similar tarea realiza Serrano (1996), quien utiliza una máquina SOM como herramienta de análisis financiero para agrupar datos. Luego integra esta técnica de aprendizaje competitivo a un sistema que utiliza AD y una RN multiperceptrón para delimitar compañías con problemas de solvencia financiera, basándose en el modelo Z-score de Altman (1968).

El éxito predictivo de las RN ante problemas crediticios puede deberse a su capacidad para filtrar ruidos que acompañan a la información financiera y a la tolerancia ante defectos en los datos. Siguiendo a Martín del Brío y Serrano-Cinca (1993), la información económica, y especialmente la que proviene de estados financieros corporativos, suele contener muchos datos correlacionados y a veces incompletos. Aun más, Brown y O'Leary (1995) destacan que una de las virtudes de las RN, es que permiten reconocer las características y particularidades de los datos y aprender de ellas. Este aprendizaje lo llevan a cabo a pesar de que no exista un modelo estructural, teórico y único que explique el fenómeno, que es lo que ocurre en este enfoque predictivo de quiebras y de ratings.

A pesar de lo ventajoso que resultan las predicciones con RN, este tipo de técnica también tiene inconvenientes. Primero, la definición excesivamente compleja de la RN puede producir que el sistema se encuentre excesivamente adaptado a los datos concretos de entrenamiento, y por ello, puede que la predicción sea poco satisfactoria (Adya y Collopy, 1998). A este problema de mínimo poder de generalización se le conoce como sobreajuste o sobreentrenamiento. En segundo lugar, dado que el

conocimiento se representa de una manera multiconectivista (distribuido a través de los pesos sinápticos en toda la red) y muy confusa, esta técnica actúa como un modelo de *caja negra*, imposibilitando la interpretación de los procesos de ajuste en la RN. El gran número de neuronas y coeficientes y la complejidad de sus relaciones impiden conocer la importancia que representa cada variable en la respuesta final del sistema y del problema crediticio (Buhmann, 2003; Hernández et al., 2004). El tercer inconveniente es que la RN obtiene la solución a través de un proceso de prueba y error, por lo que no existe una única configuración o arquitectura que sea adecuada para todos los dominios (Adya y Collopy, 1998). Esta limitación es especialmente importante en el caso de RNRP, donde se puede dar origen a que existan muchas combinaciones de pesos para un mismo conjunto de datos. Aun más, es posible que la solución encontrada por el algoritmo no necesariamente sea global (Grossberg, 1988). Por lo tanto, en el análisis de la solución se debe tener en cuenta que ésta podría ser sólo un mínimo local en vez de la solución óptima entregada por un mínimo global.

3.3.1.2 Árboles de Decisión

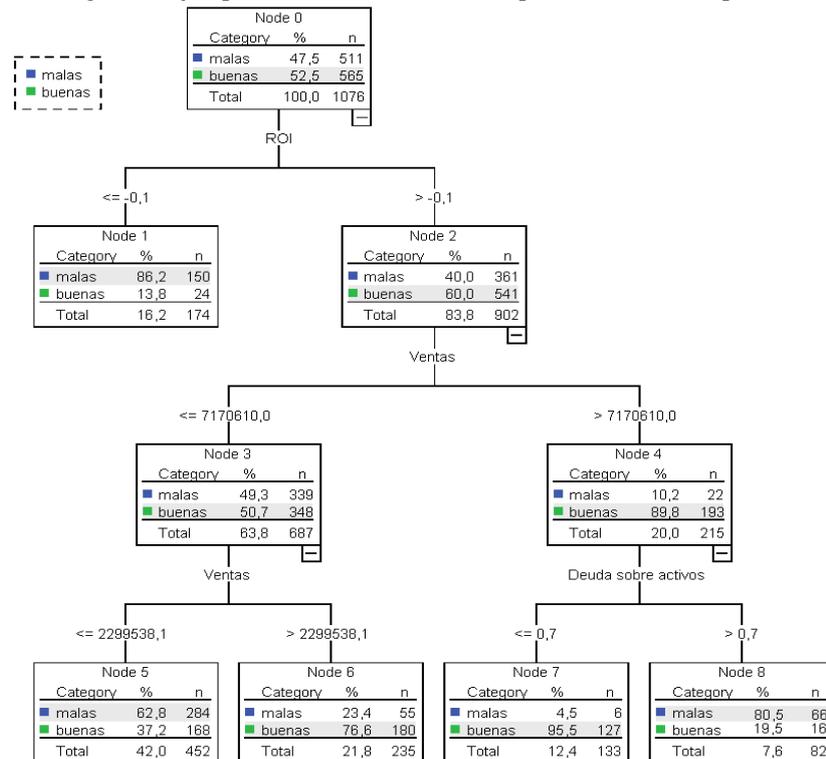
En el ámbito de las técnicas de IA los Árboles de Decisión (Decision Tree o DT) son Sistemas de Aprendizaje Automático utilizados en problemas de predicción y clasificación de diversa índole. En ocasiones este tipo de sistemas también son conocidas como Árboles de Decisión de Aprendizaje (o Decision Trees Learning) para diferenciarlas de aquellas con homónimo nombre usadas en el campo de análisis de decisiones¹³. Su origen se remonta a los años 50, con los estudios de Hovelant y Hunt (Hunt, Marin y Stone, 1966) y de algunos miembros de Harvard Business School (Raiffa y Schlaiffer, 1961). Posteriormente, la técnica propuesta por Friedman (1977), Recursive Partitioning Algorithm o RPA, ayudó a crear la base para la construcción de uno de los DT más conocidos y usados hasta ahora: CART (Classification and Regression Trees).

En general, un árbol de decisión suele definirse como “una serie de decisiones o condiciones organizadas en forma jerárquica, a modo de árbol” (Hernández et al., 2004, pág.30). Su tarea es dividir el espacio del problema en subconjuntos, hasta que estén lo suficientemente definidos en función de las clases predefinidas. El árbol está compuesto por nodos internos y arcos que los unen. Un nodo interno puede ser una hoja o una decisión, donde a cada nodo de decisión le corresponde una partición sobre un atributo de los datos y los nodos hojas son la predicción en sí misma. Para clasificar un caso nuevo se debe recorrer el árbol de acuerdo con los valores de los atributos en cada nodo. La Figura 6 muestra un ejemplo hipotético de un DT que permite distinguir empresas *buenas* de aquellas *malas*, basándose en un conjunto de atributos. En la raíz se ubica el nodo 0 (de decisión) que tiene por regla

¹³ En Análisis de Decisiones un árbol de decisión es un instrumento de apoyo a la toma de decisiones, usado para identificar la estrategia más probable que se debe emplear para alcanzar una meta deseada. Esta herramienta se expone gráficamente, modelando las decisiones y consecuencias posibles, incluyendo sus efectos, costes y beneficios. También se usan estos árboles para describir y calcular probabilidades condicionales.

distinguir entre compañías que tienen un ROI¹⁴ (uno de los atributos) mayor o menor que -0,1. Cuando el $ROI \leq -0,1$, entonces la nueva compañía queda clasificada en el nodo hoja 1 (y por tanto definida como “mala”), pero si el $ROI > -0,1$, entonces el caso queda en el nodo de decisión 2. En este nodo corresponde reconocer si la nueva compañía tiene ventas (otro atributo) mayores o no a US\$ 7.170.610, para determinar si la compañía pasará por los nodos de decisión 3 o 4, y los nodos hojas 5, 6, 7 u 8, para ser clasificada como una compañía “buena” o “mala”.

Figura 6. Ejemplo de un árbol de decisión para clasificar compañías



Fuente: elaboración propia utilizando SPSS v13.0

Algunos DT se han utilizado como clasificadores, mientras que otros para regresión, agrupamiento o cálculo de probabilidades. Para todos ellos, las variables de entrada pueden ser continuas o discretas, pero las variables de salida dependerán del tipo de Árbol de Decisión. Un DT clasificador necesitará como entrada un conjunto de variables independientes (continuas o discretas) y una variable dependiente discreta con valor único. Como salida se obtendrá la clasificación a la que corresponda la estimación. Estas son las únicas exigencias de un DT, ya que no necesita de supuestos acerca de las características de las variables o sus relaciones (Hastie, Tibshirani y Friedman, 2001; Hernández et al., 2004).

Respecto del proceso, uno de los aspectos más importantes de los DT es la elección de un criterio de partición para el problema a solucionar. La idea central es buscar particiones que consigan o

¹⁴ En este caso, este atributo es un indicador financiero que compara el beneficio obtenido en relación a la inversión realizada por una compañía. ROI es la sigla de Return on investment.

discriminen nodos más puros. El grado en que un nodo no representa un subconjunto homogéneo de casos es una indicación de impureza. La medición de esta impureza para variables dependientes categóricas (nominales u ordinales) puede estimarse con los criterios de Gain y Gain Ratio (Quinlan, 1983), Gain Ratio modificado (Quinlan, 1993), de Gini (Breiman, Friedman, Olshen y Stone, 1984), de ortogonalidad de GID3 (Fayyad, 1994) o el criterio DKM (Kearns y Mansour, 1996), entre otros.

Sobre la base de estos criterios de partición, se han construido diversos DT. CART divide los datos en particiones para maximizar la homogeneidad interna de los nodos, respecto a la variable dependiente, mientras que RPA enfoca la resolución del problema inverso, minimizando el error de clasificación esperado y de sus costos. El segundo algoritmo más conocido, ID3 (Quinlan, 1983), utiliza como criterio de partición, la introducción de aquellas variables que incorporen mayor entropía o cantidad de información al modelo. Siguiendo a Balcaen y Ooghe (2004), este criterio desfavorece a aquellos atributos cuya variable es continua. Para superar esta limitación del ID3, se desarrollaron los algoritmos C4.5 (Quinlan, 1993) y C5 (versión de C4.5 comercializada por RuleQuest Research Pty Ltd.). QUEST o Quick, Unbiased, Efficient Statistical Tree (Loh y Shih, 1997) es un DT que evita el sesgo que presentan otros métodos al favorecer los predictores con muchas categorías (SPSS, 2004). Por último, un tipo distinto de DT clasificatorio se conoce con el nombre Árbol Híbrido, que incorpora características de otros sistemas o añaden otras técnicas de aprendizaje, como redes neuronales tipo perceptrón (como la DT de Utgoff, 1989), regresiones (LMDT de Brodley y Utgoff, 1995) y métodos bayesianos¹⁵ (IND, de Bundtine, 1992).

Todos estos DT buscan un equilibrio entre clasificar correctamente el mayor número de los casos de entrenamiento y la capacidad de generalización en la predicción hacia otros conjuntos de datos, para obtener el mayor grado de aciertos. Una manera de limitar el sobreajuste es eliminar condiciones de las ramas del árbol o de algunas reglas, lo que se conoce como proceso de poda del árbol. Así los nodos que están por debajo del límite de poda se eliminan porque son demasiado específicos (Hastie et al., 2001).

Desde todas estas aproximaciones afloran ventajas e inconvenientes por el uso de DT en la predicción y clasificación de problemas de riesgo de crédito (West, 2000; Galindo y Tamayo, 2000; Baesens, Van Gestel, Viaene, et al., 2003) Las principales ventajas son:

- a) Al contrario de lo que ocurre con otras técnicas predictivas SAA, las reglas obtenidas desde un DT son fácilmente entendibles por un analista. Lo que permite una mejor interpretación económica del análisis.

¹⁵ En Estadística, los Métodos Bayesianos utilizan datos empíricos para evaluar o aproximar aquellas distribuciones probabilísticas condicionales que se presentan desde el Teorema de Bayes. Estos métodos permiten estimar estadísticos (probabilidades, promedios, etc.) acerca de un elemento individual de una población, combinando información empírica del elemento y de toda la población.

- b) La poda limita la complejidad del sistema, evitando el sobreajuste a los datos de entrenamiento, mejorando la calidad del pronóstico.
- c) Debido a que el aprendizaje de un DT es una técnica que no impone requisitos estadísticos a los datos necesarios para el entrenamiento, los efectos causados por la no-normalidad de los datos, la colinealidad entre las variables o heterocedasticidad no afectan las predicciones o clasificaciones; al contrario de lo que ocurre con las regresiones o el análisis discriminante.
- d) Los DT pueden trabajar con datos cualitativos e incluso con datos incompletos, con ruido o con errores no sistemáticos (Joos, Vanhoof, Ooghe y Sierens, 1998). El tratamiento de datos cualitativos dentro de la misma técnica (y no separada del proceso de entrenamiento o ajuste) puede ayudar a mejorar la eficiencia predictiva y el entendimiento de la relación de este tipo de variables con las cuantitativas.

Sin embargo, los DT también tienen inconvenientes, entre los que destacan:

- a) Los DT son más sensibles que el AD ante cambios en las probabilidades a priori y cambios del coste por error en la clasificación, por lo que equivocar en estos parámetros amplificaría los errores y costes de clasificación.
- b) Los DT están basados en la suposición que el evento a predecir es discreto, no se solapa y es identificable. Estas suposiciones son adecuadas para la predicción de ratings, ya que estas características han sido establecidas a priori por las agencias que las emiten. Sin embargo, estos supuestos no se cumplen en todos los problemas de riesgo crediticio. Muchas instituciones financieras que evalúan la calidad crediticia de una compañía definen un parámetro gradual y continuo para la medición del riesgo (el scoring). En este caso, para poder aplicar una DT sería necesario discretizar esta variable.
- c) En un DT la importancia relativa de las variables o atributos no puede interpretarse fácilmente. Es decir, las contribuciones de las variables son ambiguas, no hay ningún vínculo o ponderación entre las variables y la salida del árbol.

3.3.1.3 Sistemas Automáticos de Soporte Vectorial

Un tipo de Sistemas de Aprendizaje Automático que ha atraído el interés de investigadores en las últimas décadas son las Support Vector Machine (SVM) o Sistemas Automáticos de Soporte Vectorial. Siguiendo a Smola y Schölkopf, (2004), la SVM fue presentada por Boser, Guyon y Vapnik (1992) y desarrollada posteriormente en Cortes y Vapnik (1995), Vapnik (1998) y Cristianini y Shawe-Taylor (2000), entre otros. Sin embargo, los pilares sobre los cuales sustenta su teoría fueron construidos en la década de los sesenta, con elementos de la Teoría del Aprendizaje Estadístico (Vapnik, 1982).

Una SVM es un sistema de aprendizaje que construye un conjunto de hiperplanos de alta dimensión especial para tareas de clasificación o regresión. Los SVM llevan a cabo esta tarea de aprendizaje automatizado con un conjunto de ejemplos de entrenamiento, compuestos por una serie de características que le permitan disponerlos en un espacio vectorial y trazar un hiperplano que deje a todos los elementos separados. Dicha labor de separación puede ser supervisada o no-supervisada. Estos últimos realizan el entrenamiento sin la ayuda de patrones de dependencia o de salida. En contraposición, los SVM supervisados, necesitan de un patrón de referencia en la salida para el proceso de entrenamiento, como por ejemplo el rating. En esta sección sólo se hará referencia a los SVM supervisados, ya que el foco de interés es la clasificación de compañías con rating.

Los SVM binarios están enfocados a clasificar elementos que pueden pertenecer a una de dos categorías, como se muestra en la Figura 7(a), donde se dispone de un conjunto de ejemplos que pertenecen a un espacio característico $S \subset X \subseteq \mathbb{R}^n$, algunos de los cuales pertenecen a una clase A y los restantes a la clase B. Con este SVM se construye un hiperplano con parámetros que cumplen dos condiciones:

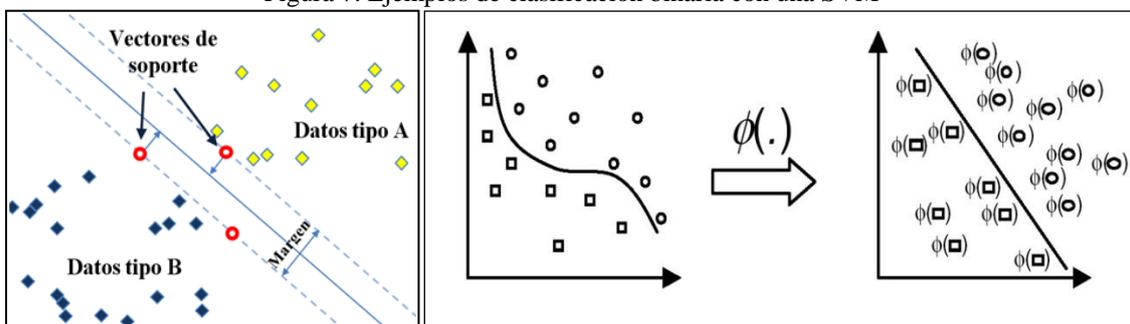
1. Los casos de la clase A queden a un lado del hiperplano y los de la clase B, queden en el otro lado, y
2. El margen del hiperplano tiene ancho máximo, igual a dos veces la distancia desde el hiperplano hasta el (o los) ejemplo(s) más cercano(s) a éste.

Además, para evitar problemas de sobreaprendizaje, al igual que la solución de la poda en las DT, entra en juego el concepto de *margen suave*, y que permite un mayor grado de generalización sobre otros conjuntos de datos. Esta idea implica permitir un margen más ancho que el óptimo, para que existan vectores de ambas clases dentro del margen o al lado incorrecto de la frontera. En la primera generación de SVM el factor de regularización C y variables de holgura pueden interpretarse como el grado de importancia que el SVM tiene el clasificar bien cada uno de los vectores, versus la importancia que tiene el lograr un margen más ancho para evitar el sobreaprendizaje. Mientras mayor sea el valor de C , más importancia se le da a la clasificación y menos a la generalización.

La definición de un SVM, permite que la solución del hiperplano óptimo pueda ser escrita como la combinación de unos pocos puntos de entrada, cuya distancia al hiperplano óptimo es igual al margen geométrico. Estos puntos se denominan vectores soporte (en la imagen izquierda de la Figura 7 aparecen encerrados con otro círculo). Sin embargo, suponer que cualquier conjunto de datos se puede separar en forma lineal es poco realista, pero es posible que ellos guarden una estructura que podría soportar una frontera de otro tipo. En tales casos, lo que se puede hacer es aplicar una transformación $\phi(\cdot)$ a los datos en el espacio de entrada, trasladándolos a un espacio de mayor dimensionalidad (denominado espacio característico) en donde un hiperplano separador sea capaz de dividir las tipos de

datos. Sin embargo, y a pesar de que esta vía es posible existe una opción menos costosa y que soluciona problemas de espacios de alta dimensionalidad: el *Kernel Trick*. Esta opción emplea una Función Núcleo (FN) o Kernel, que calcula directamente el producto interno entre dos vectores del espacio característico en un espacio de mayor dimensionalidad, sin necesidad de realizar un mapeo a dicho espacio. En la Figura 7 se observan dos casos de conjuntos de datos clasificados binariamente. La figura de la izquierda tiene datos linealmente separables (los rombos oscuros de tipo B versus los rombos claros de tipo A), mientras que en la figura de la derecha ha sido necesario una transformación con una transformación $\phi(\cdot)$, ya que los datos no eran linealmente separables (los cuadrados de los círculos). Posterior a esta separación se tendría que utilizar una transformación $\phi^{-1}(\cdot)$ que permitiese separar los datos en el espacio inicial.

Figura 7. Ejemplos de clasificación binaria con una SVM



Nota: (a) Figura izquierda: clasificación de datos linealmente separables; (b) figura derecha: proyección de los datos no-linealmente separables a un espacio de características de mayor dimensión donde si son separables linealmente, utilizado una transformación $\phi(\cdot)$.

Fuente: elaboración propia.

Una ventaja del uso de una FN es que permite trabajar en el espacio de características de mayor dimensión sin necesidad de calcular las transformaciones de los casos de aprendizaje. En la literatura y en implementaciones computacionales, como por ejemplo R, existen varias FN que son usadas en diferentes campos (Karatzoglou, Meyer y Hornil, 2006), entre las cuales las más aplicadas son la FN polinómica, la gaussiana, la sigmoide y la exponencial.

Esta definición de SVM conlleva la suposición de que se trata de un problema de biclasificación. La generalización a un SVM multclasificador se puede llevar a cabo de diferentes maneras. El enfoque multi-objetivo utiliza varios SVM binarios en conjunto. En cambio, el enfoque mono-objetivo replantea la estructura del sistema automatizado para que un solo SVM sea capaz de separar más de dos clases simultáneamente. Una característica de este último enfoque es que en el entrenamiento sólo se necesita entrenar un SVM que resulta más complejo que los multi-objetivo y que el número de restricciones crece considerablemente con el tamaño del problema. Algunas de las propuestas de esta línea son las de Crammer y Singer (2001), Joachims (2008), Ñanculef, Concha, Allende, Candel y Moraga (2009) y adaptaciones como Candel (2011).

Por otra parte, el enfoque multi-objetivo para la multclasificación es el más utilizado hasta el momento, siendo las implementaciones de *Uno contra el Resto* (one against the rest, oar-SVM) y *Uno contra Uno* (one against one, oao-SVM) las opciones más conocidas. En ambos casos se transforma el problema de K clases en un conjunto de problemas de dos clases. En oar-SVM se implementa un número K de SVMs, en donde el r -ésimo SVM está encargado de separar a los elementos de la clase r del resto de los ejemplos. Por otro lado, en oao-SVM se crean $K(K - 1)/2$ sistemas automatizados, un para cada par de clases. Una característica de los oao-SVM es que éste crea un mayor número de SVMs binarios que el oar-SVM, por lo que el tiempo de entrenamiento que requiere el oao-SVM suele ser en general menor que el requerido por el oar-SVM. En esta línea diversas propuestas continúan realizándose, por ejemplo la de Steel, Louw y Bierman (2011), quienes proponen un procedimiento de selección de variables para problemas de clasificación binaria junto con la aplicación de un kernel discriminante de Fischer.

Otra variante de este tipo de sistemas automatizados es el SVM regresivo o SVR, que fue propuesto en Drucker, Burges, Kaufman y Smola (1996). De una manera genérica, en los SVR se mantiene la estructura propuesta en los SVM de clasificación, pero encuentra una función que tenga a lo más un error de los objetivos y_i , obtenidos de los datos de entrenamiento, y al mismo tiempo, que sea lo más plana posible.

Actualmente, hay diversas propuestas de SVR, en publicaciones académicas, comercialmente y de manera abierta y pública. De manera abierta y ampliamente difundida en revistas y libros están las propuestas LIBSVM (Fan, Chen y Lin, 2005), SVMlight (Joachims, 1999, 2008), SVMtorch, Royal Holloway Support Vector Machines, mySVM, and M-SVM. De acuerdo a Zeileis, Hornik, Smola y Karatzoglou (2004), LIBSVM proporciona una robusta y rápida implementación y produce eficientes resultados en la mayoría de los problemas de clasificación y regresión¹⁶. Hay diferentes mejoras que constantemente se proponen a evaluación, como por ejemplo la propuesta de Solera (2011) en su tesis doctoral.

Al igual que otras técnicas resumidas en esta tesis, los SVM también tienen ventajas e inconvenientes. Dentro de las cualidades positivas se tiene que:

- a) Bennett y Campbell (2000) enfatizan que con los SVM se pueden crear muchas arquitecturas de aprendizaje con versatilidad. Por ejemplo, Herbrich, Graepel y Obermayer (1999) han propuesto el uso de regresiones ordinales como un enfoque complementario para problemas de clasificación y regresión cuando el espacio de salida sea ordinal. La reformulación del SVM puede realizarse a través de la modificación de la función objetivo o bien a través de la

¹⁶ Para detalles acerca de los test y referencias de distintos SVM revisar Meyer, Leisch y Hornik (2003) y Zeileis, Hornik, Smola y Karatzoglou (2004).

modificación interna de las variables de entrada, consideradas ordinalmente. Por ejemplo, Angulo (2001) y Angulo y Català (2001) proponen K-SVCR, cuyo aprendizaje tri-clasificador, aprovecha los aportes de Herbrich et al. (1999). Esta propuesta permite el diseño de una función de utilidad que introduce patrones de entrenamiento, usando una función de coste ordinal multclasificadorio.

- b) Adicionalmente, otra ventaja de la modularidad de los SVM es que en la medida que se haga una elección apropiada de la función núcleo, el SVM puede adecuarse más a la resolución del problema de clasificación. Dicha función permite entre otras cosas, trabajar la salida como una variable cualitativa, al igual que algunas técnicas DT.
- c) Al igual que otras técnicas SAA, los SVM no necesitan de supuestos acerca de los datos para resolver problemas, como ocurre con el análisis discriminante. Por ello, los problemas causados por la colinealidad entre las variables, la falta de normalidad en los datos o la homocedasticidad, no tienen sentido en este tipo de técnicas. Aun más, al usar técnicas estadísticas, los potenciales problemas generados por valores extremos son minimizados con los SVM, debido a la importancia relativa que estos puntos tienen en los algoritmos de optimización.
- d) Comparativamente con otras técnicas de predicción, los SVM superan algunos importantes problemas experimentados en distintos ámbitos, debido al robusto soporte y justificación desde la Teoría del Aprendizaje Estadístico:
 - Los SVM tienen un robusto soporte y justificación estadística desde la Teoría del Aprendizaje Estadístico. Uno de los resultados fundamentales de esta teoría permite compatibilizar la capacidad para clasificar correctamente los datos de entrenamiento, con la habilidad de clasificar correctamente gran parte de nuevos datos fuera del conjunto de entrenamiento. Es decir, se minimiza el error de generalización y el error estructural (Cristianini y Shawe-Taylor, 2000). Esta justificación estadística no se aplica en otras técnicas SAA de tipo heurístico, como las DT o las RN.
 - Con los SVM no existen soluciones que sólo sean óptimos locales (como ocurre con redes neuronales). El aprendizaje de un SVM es un problema de optimización con restricciones que se puede entender como el uso de técnicas de programación cuadrática, donde la convexidad garantiza una solución única, si ésta existe.
 - Los resultados finales son estables, reproducibles e independientes del algoritmo que se haya utilizado. Es decir, si un SVM se utiliza en dos momentos distintos en un mismo conjunto de entrenamiento, la solución final siempre será la misma. Esto no ocurre con redes neuronales, donde los resultados dependen del algoritmo y del punto inicial utilizado para el entrenamiento.

A pesar de estas importantes ventajas, el uso de SVM genera algunas dificultades.

- a) Una de ellas es que no siempre predicen mucho mejor que otras simples y sencillas técnicas, por lo que el mayor coste de implementación y cálculo se traduce en una desventaja. Existen algoritmos de SVM de tipo cuadrático que manipulan muchas y complejas operaciones matemáticas. De acuerdo con Bennett y Campbell (2000), algunos algoritmos de clasificación lineal manipulan 60 millones de datos puntuales para una aproximación concreta. Trasladando este problema a situaciones con mayor complejidad y muchas variables, algunos equipos computacionales de menor capacidad de procesamiento y memoria pueden llegar a presentar serias limitaciones. Particularmente, la implementación de regresiones multclasificadoras ordinales para resolver problemas de riesgo crediticio en bases de datos de la banca, puede presentar una ardua limitación en circunstancias que el tiempo de respuesta es importante. Sin embargo, esta desventaja cada vez es menos relevante debido a los progresos en la potencia y capacidad del hardware en la industria computacional.
- b) Otra complicación que no se ha resuelto en los SVM, al igual que en otras técnicas de predicción, es el formato y características del conjunto de datos necesarios para el entrenamiento. Concretamente, los SVM no resuelven de manera nativa los problemas causados por datos perdidos o missing values. Debido a esto, el usuario debe utilizar alguna metodología que altere lo menos posible a la base de datos para superar esta complicación. No obstante, en la literatura se han dado propuestas que complementan a los SVM y dan respuesta a este dilema (Pelckmans, de Brabanter, Suykens y De Moor, 2005; Luengo, García y Herrera, 2011; Yang, Janssens, Ruan, Cools, Bellemans y Wets, 2012).
- c) Desde la perspectiva financiera, los SVM tienen un problema de interpretación para un usuario no especializado. La difícil comprensión del algoritmo es inherente a este tipo de sistemas, ya que no fueron diseñados para que los analistas interpretaran los procesos. Sin embargo, actualmente existen algunas aproximaciones iniciales para trabajar sobre un SVM que permiten generar conjuntos de reglas interpretables. De esta manera el usuario podría entender mucho más el problema y su solución (Núñez, 2003). Los algoritmos que ayuden a interpretar lo que hace un SVM es un interesante campo a desarrollar en los siguientes años, como lo hacen Kamaloo y Abadeh (2010) al usar un Artificial Immune System (un específico tipo de SAA) para obtener reglas de clasificación desde un conjunto de datos de créditos aprobados alemanes y australianos.

3.3.1.4 Métodos basados en vecindad

El proceso de aprendizaje de muchos organismos biológicos es realizado a través de experiencias y de la comparación entre ellas. Cada vez que enfrentan una nueva situación, la decisión la toman en función de vivencias pasadas similares. Esta es la principal idea que se intenta aplicar en los Métodos Basados en Vecindad y en Casos (Instance-Based Learning o IBL): resolver problemas a partir de información extraída de un conjunto de ejemplos ya existentes, es decir, una generalización

(Hernández et al., 2004). Para llevar a cabo la resolución de problemas, los IBL necesitan dos conceptos de suma importancia. El primero de ellos es la similitud que existe entre los casos anteriores y el nuevo; lo que en términos matemáticos equivale a la distancia entre los casos. El segundo concepto distinguible en los IBL es el momento en que se realizará la exploración de la similitud: el procesamiento puede ser (i) anticipativo o (ii) retardado. Los IBL retardados aplazan la generalización hasta el momento que se conoce el nuevo caso que está fuera del conjunto de entrenamiento. Una ventaja de este enfoque es que el IBL es una combinación de aproximaciones locales, dando mayor poder de generalización a la máquina de aprendizaje. Por otra parte, los IBL anticipativos construyen una estructura de aprendizaje antes de realizar la resolución final del problema. Una cualidad de este tipo de IBL es que construyen una aproximación generalizadora dato a dato permitiendo mayor rapidez en la construcción del modelo y la predicción (Hernández et al., 2004; Russel y Norvig, 2003).

Al igual que otras técnicas de aprendizaje automático, los IBL pueden realizar tareas de clasificación o de agrupamiento. Los IBL clasificatorios son supervisados y los de agrupamiento son IBL no supervisados. La variante más conocida de los IBL clasificatorios es conocida como los *k Vecinos Más Próximos* (k Nearest Neighbor o k-NN). En esta variante se escoge un espacio métrico de datos para medir cuan distantes se encuentran unos de otros, y el enésimo caso nuevo del vector X , es clasificado según la agrupación obtenida de entre la mayoría de datos más cercanos a x_i (Henley y Hand, 1997). Para ello, es necesario elegir un conjunto de casos para entrenar k-NN con clases conocidas. Luego, una función de distancia calcula la similitud entre cada caso del conjunto de entrenamiento y cada nuevo caso que ingresa en comparación.

Otra técnica IBL supervisada es la Learning Vector Quantization (LVQ), basada en una RN de clasificación desarrollada por Kohonen (1989). La red está constituida por una sola capa de entrada, otra de salida y k neuronas grupales, que representan los prototipos π de la clasificación. Estos grupos de neuronas compiten para que el conjunto de entrenamiento se vincule cada vez más a los patrones de salida. El algoritmo va moviendo (acercando o alejando) cada π en función de la distancia entre los patrones de entrenamiento, hasta encontrar la solución que permita minimizar dicha distancia. Tanto en las k-NN como en la LVQ, las variables de entrada pueden ser continuas ó discretas. Pero las variables de salida necesarias para el entrenamiento deben ser discretas para las tareas de clasificación. El output de los IBL clasificatorios es un valor relacionado con la variable discreta, de tal manera que sea posible su clasificación (Hernández et al., 2004).

La principal ventaja de las técnicas IBL es que su aplicación no está limitada por requisitos estructurales ajenos a la misma técnica, debido a que no es necesario que los datos cumplan requisitos como por ejemplo un tipo de distribución determinada, o que no exista colinealidad entre las variables. No obstante, las IBL tienen el inconveniente de que no entregan información de los atributos (o

variables) y cómo influyen éstos en el resultado final predictivo. En caso de que la técnica de IBL esté diseñada para entregar alguna información a este respecto, los datos arrojados no son fácilmente entendibles por terceros que no sean expertos en IBL. Otro obstáculo que tiene la LVQ es la imposibilidad de asegurar que en todos los casos la solución encontrada sea un óptimo global. Además, al igual que las otras RN, la solución encontrada no es necesariamente estable, reproducible e independiente (Hernández et al., 2004; Russel y Norvig, 2003).

Finalmente, la exactitud del algoritmo del k-NN puede degradarse por la presencia de elementos irrelevantes o ajenos al fenómeno (o ruido en los datos) o si las escalas de las características de los elementos no son consistentes con su relevancia. Una aproximación particularmente destacada es el uso de Algoritmos Evolutivos para optimizar el escalamiento de los datos. Este tipo de acercamientos es revisado a continuación.

3.3.1.5 Técnicas Soft Computing

En determinadas circunstancias la falta de tolerancia hacia la ambigüedad e incertidumbre puede elevar la imprecisión en tareas predictivas o explicativas. Las técnicas de Soft Computing (Computación Flexible) intentan ayudar a resolver este tipo de problemas, dada su capacidad de adaptación frente a entornos cambiantes. La Computación Evolutiva (Evolutionary Computation) y la Lógica Difusa (Fuzzy Logic) forman parte de este tipo de sistemas de aprendizaje (Hernández et al., 2004). Basados en el paradigma evolutivo darwiniano, las técnicas de Computación Evolutiva son algoritmos que realizan procesos de búsqueda de soluciones estocásticamente en una población de soluciones candidatas. Entre las propuestas más utilizadas de este campo se encuentran los Algoritmos Genéticos (Holland, 1992), las Estrategias de Evolución (Schwefel, 1995), la Programación Evolutiva (Fogel, 1988) y la Programación Genética (Koza, 1992). Los algoritmos genéticos (AG) buscan las soluciones a través de la evolución controlada desde un conjunto de posibles soluciones, los *cromosomas*. Para ello es necesario que el algoritmo genere una población inicial de potenciales soluciones, las que se adaptarán a los nuevos estados, de acuerdo a un proceso de *competición* (mutación o autorreplicación) y variación controlada (intercambio de *material genético*). Al automatizar la competición se deben resolver, al menos, dos cuestiones: (a) debe existir una forma de elegir a los *supervivientes* del proceso de competición, medido en función de la variable dependiente, y (b) debe existir un proceso para concebir la siguiente generación de los supervivientes (Goldberg, 2002; Hernández et al, 2004).

Una cualidad de los AG es que exploran el espacio de soluciones en múltiples direcciones a la vez. En caso de que el conjunto de soluciones iniciales sean subóptimas, se elimina la tarea y se continúa el trabajo en otras direcciones. Esto le da al AG una mayor probabilidad de encontrar la solución óptima en cada ejecución, ya que puede dirigirse hacia espacios con individuos más aptos y encontrar el mejor

de ese grupo (Marczyk, 2004; Holland, 1992; Mitchell, 1996). Esto también le permite a los AG descubrir el óptimo global incluso en entornos complejos, o al menos, casi siempre puede entregar una buena solución, minimizando la posibilidad de entregar por solución sólo un óptimo local. Esto se logra debido a que pequeñas *mutaciones* permiten a cada cromosoma explorar sus proximidades, mientras que la selección enfoca el progreso, guiando al algoritmo hacia soluciones más eficientes, aunque no esté garantizada (Holland 1992; Marczyk, 2004).

Los mayores inconvenientes en las aplicaciones en riesgo crediticio es la dificultad en la interpretación, por parte de terceros que no sean expertos en AG. Es decir, la interpretación no es intuitiva. No obstante esta limitación, se han utilizado soluciones híbridas de AG vinculados con RN para replicar rating (Shin y Han, 2001).

Otra limitación de los AG se conoce como convergencia prematura, y se produce cuando, un individuo que es más apto que la mayoría, emerge muy pronto en la ejecución, reproduciéndose excesivamente y merma la diversidad de la población. Este error en el diseño del AG provoca que el algoritmo converja hacia un óptimo local de ese individuo, en lugar de rastrear hasta encontrar el óptimo global (Forrest, 1993, Mitchell, 1996). Esto es un problema especialmente común en las poblaciones pequeñas, donde se puede provocar que una solución se haga dominante sobre otras.

Otra área de Soft Computing que tiene un prominente desarrollo son los *sistemas de lógica difusa* (Fuzzy Logic o FL). Desde que la propuso Zadeh (1965), la FL ha permitido modelar la incertidumbre y el conocimiento impreciso y cualitativo de una manera similar al razonamiento humano (Hernández et al., 2004). Una de las características de la FL es que permite representar conceptos con límites borrosos (difusos), cuando su significado no está definido de forma completa y precisa. Es común que la definición mental de estos conceptos se basen en experiencias, la historia pasada y otros factores que provienen del entorno, causando un solapamiento entre las clases de los conceptos o que los límites se perciban difusamente (Syau, Hsie y Lee, 2001). Además, la extracción artificial y convencional de información no permite la misma flexibilidad que los humanos acostumbran a aplicar en la resolución de problemas. Esto se debe, fundamentalmente, a que la captura de información puede pasar por alto detalles importantes, que para un ser humano resultarían obvios.

En FL, el significado de cada término viene especificado por un *conjunto difuso* y por una *función de pertenencia*, que determina, para cualquier valor de la variable, el grado de pertenencia al conjunto difuso. Una de las ventajas de este enfoque es que permiten incorporar cualquier información disponible en la modelación, ya sea si procede de expertos humanos como si lo hace desde mediciones empíricas y modelos matemáticos (Hernández et al., 2004; Jantzen, 2007).

Las tareas que se pueden realizar con FL son variadas. Los algoritmos de FL pueden: (a) agrupar datos especificados en términos lingüísticos para ayudar al usuario a comprender sus relaciones (Turksen, 1998), o bien, para incluir información de contexto y orientar el proceso de búsqueda de información lingüística (Pedrycz, 1996); (b) clasificar datos utilizando otras arquitecturas de base, como los Árboles de Decisión (Janikow, 1998) o las redes neuronales (Rast, 1997); (c) crear reglas de asociación a través de la extracción de reglas, facilitando su entendimiento, diseño y tratamiento de datos (Chen y Wei, 2002); (d) crear relaciones de dependencia funcional entre las variables, permitiendo generalizar procesos de inferencia, o para recuperar y almacenar información difusa desde bases de datos (Hale y Sheno, 1996); y (e) sintetizar o resumir datos, convirtiéndolos en información útil para el usuario (Lee y Kim, 1997). Para la réplica de rating, Back et al. (1996) utilizan un híbrido de RN con FL y comparan sus resultados con técnicas estadísticas convencionales.

3.3.2 Comparación entre las técnicas clasificatorias

Hasta ahora se han presentado diferentes técnicas que emergen desde la Estadística y la IA. Esta división es una frontera ficticia que sirve para propósitos explicativos. En ocasiones, ambos tipos de técnicas se utilizan complementariamente, por ejemplo como ocurre en las redes neuronales bayesianas, donde se busca la solución a un problema, a través de la modelación de un conjunto de variables, con nodos neuronales que siguen determinadas distribuciones probabilísticas conjuntas. Sin embargo, en este capítulo se ha optado por esta separación para enfatizar la forma como estas técnicas se acercan a la resolución de problemas. Por una parte, las técnicas estadísticas ofrecen una aproximación basada en la comprobación de determinadas propiedades, donde el usuario supone relaciones entre variables y datos, usando herramientas para verificarlas. Estas relaciones son explícitas y directas, y muchas veces son simples y lineales (ver Tabla 18). En estas técnicas se tiene que especificar el modelo y entonces un algoritmo calcula los parámetros del modelo especificado. A estas técnicas Desai, Crook y Overstreet (1996) las denominan aproximaciones *model-driven*, es decir, aproximaciones conducidas por modelos o por teorías subyacentes, basándose en relaciones estadísticas y en supuestos de los datos. Por ejemplo, en el AD se asume, entre otras cosas, que las relaciones entre las variables son lineales y que la distribución de la densidad de población es normal. Una desventaja de las técnicas estadísticas es que sus usuarios deben dedicar esfuerzos en determinar si los supuestos del modelo se cumplen. En caso de que no se cumplan los supuestos, se debe evaluar cómo impacta dicho incumplimiento en la tarea de cálculo de los parámetros, en la predicción y en la generalización de los resultados a otros conjuntos de datos. Además, en caso de que estos supuestos no se cumplan la representación de las relaciones puede llegar a ser inadecuada y el nivel de aciertos en la predicción puede disminuir notablemente. En la Tabla 18 y en la Tabla 19 se presentan dos esquemas que definen a estas técnicas estadísticas e ilustran cuales son los requisitos necesarios para usarlas adecuadamente.

Tabla 18. Comparación entre tipos de técnicas clasificadoras

	Técnicas Estadísticas	Técnicas de Inteligencia Artificial
Relación entre las variables	Explícita, directa y a veces simple y lineal	Implícita, compleja y a veces no-lineal
Construcción del modelo	Bajo supuestos e hipótesis	Automáticamente desde los datos
Principal tarea	Cálculo de los parámetros basados en los supuestos y relaciones del modelo para la predicción	Ajustarse a la complejidad de los datos y construir un modelo para la predicción
Debilidades	i) consumo de tiempo y recursos en la verificación de supuestos, ii) dificultad para representar relaciones complejas, no-lineales o que no respondan a los supuestos.	Difícil interpretación y potencial peligro de sobreajuste de los datos

Fuente: elaboración propia.

Por el contrario, las técnicas que en este capítulo se han titulado de IA usan aproximaciones basadas en el descubrimiento de las relaciones desde los datos. Estas técnicas permiten clasificar los casos en clases cambiando la estructura del modelo; es decir, permiten modificar las relaciones existentes entre los datos, y no sólo ajustan los parámetros del modelo con fines predictivos. Siguiendo a Desai et al. (1996), estas técnicas podrían denominarse *data-driven*, ya que no es necesario una especificación previa del modelo; al contrario de las *model-driven*. Por ejemplo, una RN aprende las relaciones inherentes entre los datos. Por ello, las aproximaciones del tipo *data-driven* resultan atractivas para la resolución de problemas sobre los que se tiene poco conocimiento sobre las relaciones que existen entre los datos, generando arquitecturas complejas y relativamente grandes. Una potencial desventaja para este tipo de modelos suele ser la difícil tarea de interpretación de las relaciones u operaciones construidas por la técnica. Además, el sobreajuste y falta de generalización son dos debilidades que se intentan subsanar. Por ello, en estas técnicas de IA se han dedicado grandes esfuerzos para evitar esta sobre-especificación en la etapa de entrenamiento. Un ejemplo de ello es la tarea de poda en los DT, la selección de un mayor valor de k en los métodos k -NN, o la introducción de variables de holgura en los SVM.

Otra forma de entender las diferencias entre las técnicas estadísticas y las de IA es a través de la caracterización de los datos de entrada y de salida. Un cuadro resumen de este enfoque se ofrece en la Tabla 19, donde se muestran las propiedades que deben cumplir los datos de ingreso y salida usados en las técnicas descritas para tareas de clasificación y las relaciones que les son necesarias. La ausencia de indicador en esta tabla indica que no corresponde aplicar dicha exigencia o bien que no es posible utilizar dicho tipo de variable. De esta tabla se puede apreciar que todas las técnicas de IA no precisan de requisito alguno para usar la técnica; en cambio en las técnicas estadísticas es requisito que los errores sean independientes entre sí.

Por otro lado, todas las técnicas de IA permiten o no, linealidad en la relación entre las variables, pero no es una exigencia que deba cumplir necesariamente. Además, se muestra que todas las técnicas estadísticas necesitan que la variable dependiente sólo sea numérica y discreta. En cambio, en las técnicas de IA, la posibilidad de incluir variables discretas, continuas o no-numéricas dependerá de

cómo se ha construido la arquitectura. En general, las técnicas estadísticas permiten menos opciones para elegir el tipo de variables que se pueden incluir en modelo. Para las tareas de clasificación, las variables dependientes siempre deben ser discretas. En este tipo de técnicas se deben incluir variables independientes continuas, aunque se permiten en algunas aproximaciones la inclusión de variables discretas (como las dummy).

Tabla 19. Características de las variables de entrada y salida de las técnicas de clasificación.

	Características	Técnicas Estadísticas				Técnicas de I.A. clasificatorias					
		AD	PL	P	RL	RN	DT	SVM	IBL	AG	FL
Ingreso de datos	<u>VARIABLES DEPENDIENTES:</u>										
	numéricas discretas	r	r	r	r	p	p	p	p	p	p
	numéricas continuas					na	na	na	na	na	na
	no-numéricas					na	p	na	na	na	na
	<u>VARIABLES INDEPENDIENTES:</u>										
	numéricas discretas	na	na	na	na	si	p	na	na	na	p
numéricas continuas	r	r	r	r	p	p	p	p	p	p	
no-numéricas					p	p	na	p	p	p	
Tipos de relaciones	linealidad de las relaciones	r	r	r	r	p	p	p	p	p	p
	no-linealidad de las relaciones					p	p	p	p	p	p
Requisitos necesarios en el modelo para aplicarlo	independencia de los errores	r	r	r	r						
	homocedasticidad	r	r	r	r						
	errores $\sim N(\sigma, \mu)$	r	r	r							
	errores $\sim \text{Logística}(\alpha, \beta)$				r						
	variables dependientes $\sim N(\sigma, \mu)$	r									
grupos con igual covarianza	r										
Salidas de datos (v. dependiente)	numérica continua	r	r	r	r	p				p	p
	numérica discreta					p	r	r	r	p	p
	probabilidad de ocurrencia	p	p	r	r	na	na	na	na	na	na

NOTA: “r” indica que es un requisito necesario para la aplicación de la técnica, “p” indica que la técnica permite esta condición en todas las variantes de la técnica, y “na” indica que es posible que se permita esta característica, aunque puede en algunas variantes de la técnica que no sea aceptable. Las siguientes son abreviaturas y sus correspondencias: **AD** es Análisis Discriminante; **PL** es el modelo de Probabilidad Lineal; **P** es modelo Probit; **RL** es Regresión Logística; **RN** es Red Neuronal; **DT** es Árbol de Decisión; **SVM** es una Máquina de Soporte Vectorial; **IBL** es Métodos Basados en Vecindad; **AG** es Algoritmo Genético; **FL** es Lógica Difusa.

Las salidas que arrojan las técnicas estadísticas son valores continuos, nunca discretos, y menos aún no-numéricos. Sin embargo, sus rangos de valores son diferentes: por ejemplo, la regresión logística tiene una salida entre 0 y 1, mientras que en una AD el valor $y_i \in \mathbb{R}$. En cambio, en todas las técnicas de IA la salida de datos (el pronóstico) dependerá del tipo de variable de entrada elegida y de la arquitectura diseñada.

3.4 Cuantificación de la bondad de la predicción

Una vez elegida y realizada la predicción con más de una técnica clasificatoria, es común que se proceda a evaluar su desempeño, y comparar sus resultados. Para estos efectos, en la réplica de rating se suelen utilizar dos herramientas de comparación: las tablas de contingencia junto a la medición del grado de éxito logrado y las curvas Receiver Operating Characteristic (ROC) y el AUROC. El análisis

basado en el coste de los errores es otro enfoque para hacer evaluaciones predictivas en riesgo crediticio, pero no se han aplicado en la réplica de rating, sino en la concesión de créditos bancarios. El motivo de ello es porque la banca posee muchos datos para asignar el coste de errar (Pacey y Pham, 1990; Tam y Kiang, 1992; Frydman et al., 1985; West, 2000). En cambio, en el uso de rating, no hay datos ni congruencia de cuál debería ser el coste de errar.

3.4.1 Tablas de contingencia y medición del nivel de aciertos

La manera más usual para medir la eficiencia en la clasificación es a través del porcentaje de acierto global de las predicciones. Existen diferentes formas de evaluar el nivel de acierto (Liu, Frazier y Kumar, 2007), sin embargo, en la réplica de rating suele medirse la tasa de acierto como el acierto total dividido por el número total de casos. Para su obtención es necesario conocer la tabla o matriz de contingencia o de confusión (Stehman, 1997). Dicha tabla incluye tanto los aciertos como los errores para cada una de las clasificaciones, es decir, muestra los casos de clases predichas comparadas con los valores reales. Esta tabla es la principal y central fuente de información para evaluar la bondad de la predicción (Foody, 2002; Liu, Frazier y Kumar, 2007). La Tabla 20 expone los resultados genéricos que se podrían obtener en una matriz de confusión.

Tabla 20. Matriz de confusión genérica

		Valores estimados	
		Tipo A	Tipo B
Valores reales	Tipo A	verdadero positivo (VP)	falso negativo (FN)
	Tipo B	falso positivo (FP)	verdadero negativo (VN)

Fuente: Elaboración propia

El verdadero negativo (VN) y el verdadero positivo (VP) son los aciertos en las predicciones y el falso positivo (FP) y el falso negativo (FN) son los errores. FP es predecir que ocurre A cuando en realidad ocurre B, y FN es el error inverso. Todos éstos se pueden presentar en términos absolutos o como porcentaje, tanto del total de datos como del subgrupo al que pertenece la clasificación real. En la medida que VP y VN sean mayores, mejor es el desempeño de la técnica clasificatoria. Esta tabla puede ser extensible a k clases. En este último caso la práctica habitual es identificar y separar los errores de clasificación de acuerdo a cuan distantes se encuentran de la diagonal (Koh, 1992; Bessis, 2002). En la Tabla 21 se muestra un ejemplo hipotético donde se exponen los errores de clasificación, según su distancia a la diagonal de la matriz.

Tabla 21. Matriz de confusión

		Pronóstico							Errores
		Clase1	Clase2	Clase3	Clase4	Clase5	Clase6	Clase7	
Clase real	Clase1	13	3	2	0	0	0	0	28%
	Clase2	19	33	15	2	0	0	0	52%
	Clase3	16	161	245	94	18	1	0	54%
	Clase4	0	2	56	166	92	8	3	49%
	Clase5	0	0	0	8	61	16	6	33%
	Clase6	0	0	0	0	9	12	2	48%
	Clase7	0	0	0	0	3	2	8	38%
Aciertos		27%	17%	77%	61%	33%	31%	42%	
Aciertos totales:					538	(50,0%)			
Total de errores de clase subvaluada:					262	(24,3%)			
Total de errores de clase sobrevaluada:					276	(25,7%)			
Total de errores +/- 1 muesca o casilla:					477	(44,3%)			
Total de errores +/- 2 muescas o casillas:					57	(5,3%)			
Total de errores +/- 3 muescas o casillas:					4	(0,4%)			

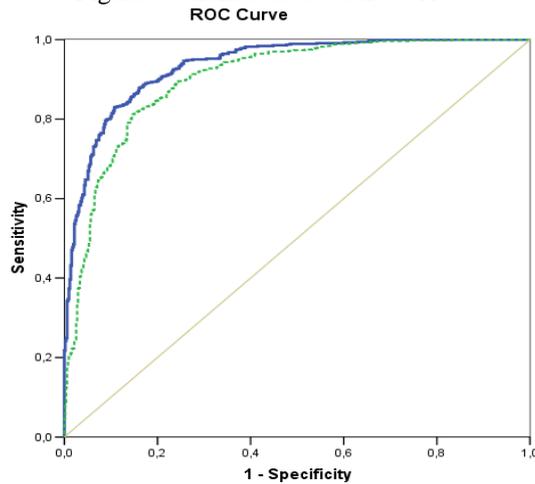
Fuente: Elaboración propia

En la misma línea, también se puede separar los errores de sobrestimación de los errores de subestimación. En el ejemplo antes expuesto hay 262 errores de subestimación, lo que equivale al 24,3% de todos los pronósticos. Los errores por sobrevaloración se encuentran a la izquierda de la diagonal y que en este ejemplo ascendió al 25,7%. De la misma manera se puede evaluar la simetría de los errores de pronóstico, que estaría dado por el cociente entre el error de sobrestimación y el de subestimación. La simetría del error del pronóstico para ejemplo anterior es igual a 1,053 (=276/262). Esto indica que la técnica se equivoca más en sobrevalorar que en subvalorar las predicciones en un 5,3%.

3.4.2 Curvas ROC y análisis AUROC

El análisis ROC (Receiver Operating Characteristic) es un diagrama gráfico de la sensibilidad versus la especificidad (1 – especificidad) para mostrar cómo varía su umbral de discriminación en un sistema binario de clasificación. En la Figura 8 se presentan curvas ROC de dos modelos hipotéticos. La sensibilidad es la probabilidad de que ocurra un VP (graficada en el eje-y), mientras que la especificidad es la probabilidad que ocurra un VN (1- VN está graficada en el eje-x). Por lo tanto, el ROC puede ser representado por las fracciones de VP contra los FP. Cuando se trata de una biclasificación es posible evaluar la técnica con ROC siempre que desde la técnica puedan obtenerse las probabilidades de acierto para cada clase (Hernández et al., 2004; Witten y Frank, 2000). Por lo tanto, con ROC es posible comparar dos o más técnicas o procedimientos de clasificación. En este ejemplo, el modelo que genera la curva continua (de color oscuro) tiene mayor precisión que el generado para la curva punteada: la línea continua siempre se encuentra por encima de la punteada. La posibilidad de visualizar las curvas ROC permite una fácil comparación entre los modelos.

Figura 8. Gráfica de dos curvas ROC



Fuente: Elaboración propia

El mejor método hipotético de una predicción representaría un punto en la esquina superior izquierda del espacio ROC, es decir, el 100% la sensibilidad (donde se encuentran todos los VP) y el 100% especificidad (donde no se encuentra ningún FP). Un predictor totalmente aleatorio daría como resultado la recta diagonal del gráfico, conocida también como “línea de no-discriminación”.

Otra forma que comparar modelos o técnicas de clasificación es a través de AUROC (Area Under ROC curve), donde la mejor predicción será aquella con mayor área bajo la superficie de la línea convexa. La principal ventaja de este criterio de evaluación es la fácil comparación cuando se poseen varias técnicas (incluso si algunas de ellas se intersectan en más de un punto) y distintos conjuntos de datos para comparar. Un ejemplo de ello se presenta en la Tabla 22.

Tabla 22. Comparación de la AUROC de distintas técnicas y distintos conjuntos de datos

	Técnica	Bene1	Bene2	Alem.	Austrl.	UK1	UK2	UK3	UK4
Para-métricas	AD lineal	77,1	77,1	78,4	92,8	64,1	73,6	74,4	72,3
	AD Cuadrática	73,4	72,4	71,8	91,5	63,3	72,1	68,1	68,3
	Regres.Logística	77	78	77,7	93,2	63,9	73	74,6	72,7
	Program.Lineal	76,1	77,5	76,3	92,6	56,4	62,3	62	62,2
SVM	RBF LS-SVM	77,6	77,8	77,4	93,2	65	74,7	72,9	73,1
	Lin LS-SVM	76,9	77,1	78,4	92,9	64,4	73,7	73,8	72,5
	RBF SVM	76,7	77,1	77,2	92,6	59,3	65,4	67,3	63,4
	Lin SVM	75,9	77,5	76,6	93,6	56,4	63,9	62,9	62,9
RN	RN MP	76,9	79,1	78,7	91,7	66,4	75,8	74,6	72,9
	Naive Bayesian	76,5	70,6	77,2	93,1	65,8	73,7	66,9	67,9
	TAN	75,5	78,2	78,3	93,4	66,8	74,5	64	66,6
DT	C4.5	72,2	71,1	74,7	91,6	56,1	65,7	50	49,9
	C4.5 c/poda	71,6	74,2	62	85,3	61,7	70,4	60,3	68,4
	C4.5 discreta	73	73,2	74,6	93,1	50	50	50,4	49,9
	C4.5 c/p discreta	73	71,5	64,4	93,1	65,2	71,5	66,7	64,9
K-nn	KNN10	71,7	69,6	70,2	91,4	58,9	65,4	63	67
	KNN100	74,9	71,5	76,1	93	62,8	69,9	70	70,4
	Muestra	3123	7190	9360	11700	3960	1980	1000	690

Fuente: Baesens et al. (2003).

Nota: RN MP= Red neuronal multiperceptrón; TAN= RN Tree Augmented Naive Bayesian LS-SVM= SVM con función núcleo de AD. Bene1 y Bene2 corresponden a dos bases de datos de BENELUX; “Alem” corresponde a una base de datos alemana, “Austrl” corresponde a una base de datos australiana y UK1, UK2, UK3 y UK4 son bases de datos inglesas.

En este ejemplo, Baesens et al. (2003) realizan una comparación con datos de créditos bancarios de distintos países, pero no se cruzan las comparaciones entre distintas bases de datos. La escala de grises (o colores) de las casillas indican el grado de aciertos, en la medida que la celda es más oscura, mayor es el AUROC. Por ejemplo, para la base de datos de Australia, la mayor AUROC se obtuvo con una SVM lineal y la más baja con el árbol de decisión C4.5 con poda. En general, los SVM y las RN son las técnicas con mayores niveles de AUROC, y por lo tanto, con mayor nivel de aciertos.

A pesar de lo útil que son estos métodos de comparación, la principal limitación es que sirven para problemas biclasificatorios. Srinivasan (1999) ha estudiado la manera de ampliar el análisis ROC para multclasificaciones, pero el cálculo de las superficies convexas no parece posible hasta la fecha.

3.5 Comparación de resultados predictivos de rating crediticio

En las secciones anteriores se han expuesto las transformaciones en las variables más utilizadas en la evaluación del riesgo crediticio individual, las metodologías de muestreo y validación más empleadas en predicciones crediticias, un abanico de técnicas para la predicción de fenómenos crediticios, y los procedimientos más usados para evaluarlas. En esta última sección se exponen los resultados de las predicciones realizadas en la literatura financiera con técnicas estadísticas y de IA. Sin embargo, antes de ello es necesario puntualizar la existencia de diferencias que entorpecen la comparación de resultados, o al menos, el lector debería tener la precaución de considerarlas para su interpretación.

Una de las primeras diferencias notorias entre diversos trabajos es que se utilizan diferentes bases de datos para realizar las predicciones. Aunque este no es un problema para realizar las predicciones, si es un obstáculo para comparar los niveles de aciertos entre las diversas investigaciones. A pesar de que existen excepciones, la mayoría utiliza distintos conjuntos de datos debido a que las muestras contienen distintas compañías extraídas en distintos períodos de tiempo. En algunos trabajos, los ratios que alimentan las variables explicativas desde reputadas bases de datos (como Compustat) son similares o iguales, pero las compañías seleccionadas suelen ser distintas, y en la mayoría de las veces el tamaño de la muestra también difiere. Esto se agrava cuando los períodos de tiempo son distintos, debido a las diferencias que hay entre los procesos y ciclos económicos subyacentes. En contraposición, en otras disciplinas científicas, se suelen usar conjuntos de datos comunes, e incluso, libremente disponibles para que los resultados entre diferentes investigaciones sean comparables. Por ejemplo, Salzberg (1997) y Bouckaert y Verboven (2004) utilizan datos de UC Irving Repository.

En la Tabla 23 se muestra un conjunto de artículos publicados acerca de la réplica de rating de empresas y de bonos corporativos. Se excluyen de esta revisión los estudios realizados sobre réplicas

de empresas del sector financiero y seguros y de réplicas de otros tipos de rating, como por ejemplo los bonos soberanos, de ayuntamientos o gobiernos autónomos. En el Anexo B se amplía la información contenida en esta tabla (ver Tabla A 3). En la Tabla 23 se pueden observar:

- los períodos de tiempo para los cuales se usan los datos,
- el número de clases de la calificación que ha sido replicada y su distribución,
- las técnicas utilizadas para replicar el rating y el máximo de variables usadas,
- los máximos porcentajes de acierto para cada estudio,
- el número de datos que se han usado para realizar las pruebas (sólo algunos artículos contienen información de las proporciones de datos en el diseño de experimento),
- el tipo de validación utilizada, si ha sido usada,
- el (los) país (es) donde se ubican las empresas o bonos con rating y
- la amplitud de años utilizados para los datos de las compañías.

Tabla 23. Artículos publicados en los que hay clasificación de ratings de empresas no financieras

Artículo	clases	tipo de clases	técnicas	variables	acierto (%)	muestra	validación	Datos en el Tiempo
Horrigan (1966)	9	AAA ... C	Rlin.	6	52 - 58	200	holdout	1959... 1964
Pogue y Soldofsky (1969)	4	Aaa Baa	Rlin.	6	80	102 y 10	holdout	1961 a 1966
West (1970)	9	Aaa...Baa	Rlin.	4	62	150	holdout	1963 a 1968
Kaplan y Urwitz (1979)	6	Aaa ... B	RL, probit	10	55, 50	120+140 y 67	holdout	1971... 1974
Pinches y Mingo (1973)	5	Aa ... B	AD	6	58 - 65	132 y 48	holdout	1967 y 1968
Dutta y Shekhar (1988)	2	AA v/s noAA	RNRP, Rlog.	10	65 a 92	30 y 17	holdout	1983 y 1984
Surkan y Singleton (1990)	2	Aaa v/s A1,A2,A3	RNRP	7	88	51 y 35	holdout	1982 a 1988
Garavaglia (1991)	17	AAA, ..., B-, (CCC,....D)	RNCP	87	23	156 y 641	S/I/C	1987
	3	I, E, M	RNCP	87	84	156 y 641	S/I/C	1987
Utans y Moody (1991)	17	AAA ... B-	Rlin., RNPM	10	21 a 30	196 y 196	5-f cv	S/I/C
Han y Jhee (1993)	4	A1 ... B	Adaline, AD	26	54 a 91	136 y 80	holdout	1985, 1986,1987
Kim et al. (1993)	6	Aaa ... B	Rlin.,AD,Rlog	8	36 a 43	110, 58 y 60	holdout	1985 a 1991
	6	Aaa ... B	RNRP+LVQ,RBF	8	31 a 55	110, 58 y 60	holdout	1985 a 1991
Moody y Utans (1994)	17	AAA ... B-	Rlin, RNPM	10	21 a 31	196 y 196	5-f cv	S/I/C
	5	AAA ... B-	RN PM	10	63 - 85	196 y 196	5-f cv	S/I/C
Maher y Sen (1997)	6	Aaa ... B	Rlin,RNRP	7	62 a 70	179, 60 y 60	holdout	1.1.90 a 21.12.93
Kwon et al. (1997)	5	A1 ... C	AD, OPP,RNRP	26	58 a 74	3085	holdout	1991 a 1993
Chaveesuk et al. (1999)	6	AAA... B	Rlin, Rlog	8	48 a 53	60, 30 y 30	holdout	1997 y 1996
	6	AAA... B	RNRP,RBF,LVQ	8	37 a 57	60, 30 y 30	holdout	1997 y 1996
Shin y Han (2001)	5	A1... C	AD, ID3, CBR	12	59 a 62	3486 y 400	S/I/C	1991 a 1995
	5	A1... C	CBR+GA	12	62 a 70	3486 y 400	S/I/C	1991 a 1995
Rovira et al. (2004)	2	I v/s (E+M)	RBF	21	79	319, 160 y 159	holdout	2001
Moro (2004)	2	AAA v/s BB	AD, SVM	13	62 a 100	84	S/I/C	1998 y 1999
Huang et al. (2004)	5	AAA...BB	Rlog,RNRP,SVM	6	73 a 80	74 ?	10-cv y L1O	1998 a 2002
	5	AAA...BB	Rlog,RNRP,SVM	16	70 a 76	74 ?	10-cv y L1O	1998 a 2002
	5	AA... B	Rlog,RNRP,SVM	5	75 a 81	265 ?	10-cv y L1O	1991 a 2000
	5	AA... B	Rlog,RNRP,SVM	14	75 a 80	265 ?	10-cv y L1O	1991 a 2000
Rovira et al. (2005)	2	I v/s (E+M)	AD, logit, SVM	32	73 a 89	1076	2-cv	2002
		I v/s (E+M)	AD, logit, SVM	10	81 a 85	1076	2-cv	2002
Lee (2007)	5	AAA, AA, A, B, C	AD, CBR	10	58 a 63	3017	holdout (80;20)%	1997 a 2002
			RN	10	55 a 60	3017	holdout (60;20;20)%	1997 a 2002
			SVM	10	35 a 67	3017	5-cv y holdout	1997 a 2002
Ahn y Kim (2011)	5	A1, A2, A3, B+C	RN	14	65 a 70	1295	5-cv y holdout	2002
			SVM	14	67 a 76	1295	5-cv y holdout	2002

Nota: (1) este porcentaje corresponde a la tasa de ajuste de la regresión, las predicciones no se van validado fuera de la muestra si no está especificado como holdout. Siglas no explicadas anteriormente; **Rlin** es regresión lineal; **Rlog** es regresión logística; **RNRP** es red neuronal retropropagación; **RNCP** es una red neuronal Counter-Propagation; **RNPM** es una red neuronal Propagación Multicapa; **OPP** es una red Ordinal Pairwise Partitioning; **L1O** es leave-one-out; **k-cv** significa k carpetas de validación cruzada; **S/I/C** es Sin Información o con información Confusa; **I** es Inversión (rating AAA...BBB), **E** es Especulativo (rating BB...CCC) y **M** es Mala calidad (rating D).

Fuente: Elaboración propia.

De acuerdo con lo que se puede observar en la Tabla 23, el número de clases es bastante amplio y heterogéneo, ya que va desde 2 hasta 17, aunque la mayor parte de los estudios incluye 5 o 6 clases, y la distribución de clases (“tipos de clases” en la tabla) usualmente va desde AAA hasta B. Es decir, los estudios antes del año 2007 concentran su análisis y réplica en rating de muy buena calificación crediticia, separando las clases de rating en 5 o 6. La excepción es el estudio de Garavaglia (1991). En la medida que los estudios clasifican en un mayor número de clases, menor es el nivel relativo de aciertos. Por lo tanto, para comparar los aciertos obtenidos entre distintos estudios es necesario hacerlo entre aquellos que utilizan similar número de clases y entre los mismos tipos de rating. En otras palabras, el tipo de clases también es un aspecto relevante, ya que las características subyacentes de la calidad crediticia de las compañías y de la capacidad de predecir el rating asociado a ellas difieren notablemente. El nivel de aciertos de una predicción biclasificatoria entre compañías con rating AA versus las restantes (usada en Dutta y Shekhar, 1988) no necesariamente tiene que ser similar al obtenido en una predicción sobre compañías con grado de inversión (AAA,..., BBB) versus compañías con grado especulativo (BB,..., D) (usada en Rovira et al., 2004). El motivo es que las características de las empresas en una zona de calidad crediticia más reducida (por ejemplo entorno a AAA, +AA, AA y -AA) son más homogéneas, lo que permitiría a la técnica clasificatoria realizar un proceso de ajuste o entrenamiento más preciso que si lo hiciese en un espectro mucho más amplio.

Otra diferencia que se observa estriba en los diferentes períodos de tiempo que abarcan, tanto en la longitud temporal como en los momentos en que son elegidos los conjuntos de datos (ver Tabla 23). Puede ser inconsistente la comparación entre estudios que se basan en distintas longitudes de tiempo, sobre todo cuando los tamaños de las bases de datos son pequeños. Obsérvese el ejemplo de la base de datos usada en Huang et al. (2004), donde un conjunto de predicciones se realiza con 74 compañías de Taiwán por 5 años. El subconjunto de entrenamiento tiene las mismas compañías que en la validación, por lo que los resultados de aciertos pueden estar sobredimensionados. Esto puede ocurrir ya que los algoritmos de aprendizaje pueden haber aprendido muy bien la relación entre determinadas y específicas compañías, pero pueden causar grandes errores de predicción cuando los patrones de otras compañías no concuerden con los entrenados. La diferencia entre los niveles de acierto se acentúa cuando se han utilizado conjuntos de datos de entrenamiento diferentes al de validación (ver casos de Garavaglia (1991) y Rovira et al. (2004) en la Tabla 23). La segunda precaución que se debe considerar al comparar resultados de aciertos entre estudios con datos de diferentes períodos de tiempo, tiene que ver con la capacidad que tiene el modelo para predecir acertadamente cuando las condiciones del entorno han cambiado y la capacidad que tiene la técnica de clasificación para extrapolar minimizando el sobreajuste. Como se ha mencionado en el capítulo anterior, existen evidencias que indican que el riesgo de crédito está fuertemente ligado a las condiciones económicas del deudor. Por lo tanto, un modelo podría tener un elevado nivel de aciertos en un período de tiempo determinado y un muy pobre en otro período cuando las condiciones económicas han cambiado

notoriamente. Como se ha planteado en el capítulo anterior, en la práctica financiera se ha puesto como solución a este problema el continuo ajuste o entrenamiento a través del tiempo, pero esto no resuelve el dilema de la distorsión en la comparación de los niveles de acierto.

Dos aspectos adicionales sobre los cuales es apropiado detenerse, antes de interpretar los resultados de estos artículos, tratan acerca del tamaño de la muestra y el diseño de experimentación realizado (la forma y proporción de la submuestra para validar la predicción). La mayor parte de los trabajos realizados de esta revisión de la literatura tienen pequeñas muestras: en Dutta y Shekhar (1988) la muestra total no alcanzaba los 50 casos y la mediana de los tamaños muestrales de la Tabla 23 es de 228 casos. Si la muestra es demasiado pequeña, existe la duda razonable de cuan extrapolables sean los resultados y conclusiones a otras poblaciones. No existe consenso acerca de qué técnica es más apropiada para predicciones cuando la base de datos es pequeña. Hernández et al. (2004) indican que algunos SAA son más robustos y eficientes en el nivel de acierto cuando hay pocos datos para el entrenamiento que las técnicas estadísticas. En cambio, Back et al. (1997) concluyen que las predicciones de RN y algunos SAA resultan más acertadas que el análisis discriminante y la regresión logística cuando los tamaños de la muestra son de 400 casos, pero no cuando los tamaños muestrales son de 200 o 100 casos. Esta capacidad de predicción y la estabilidad de los resultados también depende de la manera como se plantee el diseño experimental. Existen evidencias que el uso de diferentes metodologías para validar los resultados puede causar variaciones en los niveles de acierto de las predicciones. La elección del diseño de experimentación dependerá de la cantidad de casos disponibles para entrenar y validar. Por ejemplo, es conocido que la validación cruzada es recomendada frente a la validación simple cuando los tamaños de muestra son pequeños, ya que obtienen mejores resultados y más fiables (Kohavi, 1995). De hecho, en los últimos años el uso de la validación cruzada es más frecuente (ver Tabla 23). Por lo tanto, para hacer una comparación entre los resultados de acierto de las técnicas de predicción utilizadas en distintos trabajos de investigación, es necesario conocer el tamaño de datos sobre el cual se hace el estudio y la forma como se llevó el diseño de experimentación. Sin embargo, no todos los trabajos detallan la metodología aplicada al experimento. Por ejemplo en Garavaglia (1991) y en Shin y Han (2001) no es posible conocer con detalles las proporciones que se han destinado para entrenamiento y para pruebas, ni tampoco si se han repetido en varias oportunidades los experimentos para obtener estadísticos más robustos.

Un último aspecto que se puede verificar en la Tabla 23 es que el número de variables utilizadas en los estudios de clasificación de rating es muy variable (el mínimo es 4 y el máximo 87). La mayoría de los trabajos revisados primero analizan un grupo de variables disponibles, de las cuales finalmente seleccionan aquellas que les ayuden a clasificar con mayor exactitud el rating (la mediana es 10 variables por modelo). En algunos estudios se señala la metodología usada para seleccionar las variables (Pinches y Mingo, 1973; Kaplan y Urwitz, 1979; Rovira, Agell et al., 2004), pero la mayoría

de los estudios más contemporáneos revisados entrega muy poca información (Ahn y Kim, 2011) o simplemente no la entregan (Moro, 2004; Huang et al, 2004).

3.5.1 Resultados de las predicciones

Se resumen a continuación los resultados de las predicciones obtenidos en la literatura consultada, según el tipo de técnica utilizada.

Regresión logística

Las primeras aplicaciones de logit (o regresión logística) en el ámbito del riesgo de crédito se encuentran en Martín (1977), Ohlson (1980) y Hammer (1983). Actualmente, logit es considerado un buen modelo de predicción y clasificación en el ámbito crediticio, y suele utilizarse para comparaciones frente a técnicas alternativas (Fletcher y Goss, 1993; Back et al., 1996; Laitinen y Kankaanpää, 1999; Huang, Chen, et al., 2004; Baesens et al., 2003). Uno de los primeros trabajos de predicción de ratings que usó logit es el de Horrigan (1966), donde se obtuvo un 58% de predicciones correctas de rating de Moody's (en 9 clases) para 200 bonos norteamericanos entre 1961 y 1964, utilizando como variables explicativas ratios financieras de los estados contables. Pogue y Soldofsky (1969) utilizaron también una regresión que predecía correctamente un 80% de los casos de ratings (separados en 4 clases), pero no realizaron una validación fuera de la muestra. Esto significa que probablemente este nivel de aciertos se encuentre sobrestimado. West (1970) logró un 62% de aciertos para los ratings de Moody's (en 9 clases) de bonos corporativos norteamericanos de 1953 y 60% de aciertos para datos de bonos de 1961. Kaplan y Urwitz (1979) utilizan dos conjuntos de muestras de bonos corporativos de EUA (una de bonos con rating sin cambios o transiciones y otra de bonos recién emitidos) para predecir los ratings (en 6 clases) con una regresión de probabilidad lineal y con probit. Las predicciones regresivas con OLS (55% de aciertos) fueron levemente más certeras que las obtenidas con el probit (50% de aciertos).

Análisis Discriminante

El primer trabajo vinculado con riesgo crediticio que utilizó AD fue el de Durand (1941) y los primeros en el ámbito corporativo fueron los estudios de Altman (1968), Orgler (1970), Deakin (1972) y Blum (1974). Hasta hoy se utiliza esta técnica como un punto de referencia para comparar la precisión de las predicciones con otras técnicas alternativas (Coats y Fan, 1992; Back et al., 1996; Laitinen y Kankaanpää, 1999). En la predicción de ratings, Pinches y Mingo (1973) utilizaron un AD para desarrollar un modelo que obtuvo un 65% y 56% de aciertos para dos conjuntos de datos de bonos norteamericanos con rating (en 5 clases) de Moody's (entre los años 1967-1968 y 1969, respectivamente). Michel (1977) también utiliza un AD para caracterizar cuatro grupos de bonos con rating de Moody's de municipios de 50 ciudades en EUA entre 1967 y 1971, obteniendo un 58% de aciertos.

Redes Neuronales

El uso de redes neuronales en la predicción de rating de obligaciones comienza en la década de los ochenta. Uno de los primeros trabajos en esta línea es el de Dutta y Shekhar (1988), quienes aplican una RN perceptrón multicapa y comparan los resultados obtenidos con AD y regresión lineal. En este caso las RN predijeron con mayor precisión los ratings. Su objetivo era clasificar bonos en dos clases (AA o distinto de AA). Para ello utilizaron variables financieras de los trabajos de Horrigan (1966) y Pinches y Mingo (1973). Una tarea similar a la de Dutta y Shekhar (1988) es la que realizan Utans y Moody (1991) y Moody y Utans (1994), pero utilizan un mayor número de clases (17 en total) y prueban RN con distintas arquitecturas (cambiando el número de capas ocultas y de pesos). En ambos casos los niveles de acierto con RN son superiores a las predicciones realizadas con regresiones lineales (entre un 8% y un 9% más precisas).

Surkan y Singleton (1990) también predicen ratings (en dos clases: Aaa versus A1, A2 y A3) de 8 bonos de compañías telefónicas de EUA con perceptrón multicapa. El trabajo incluye siete variables de estados financieros de estas empresas y se analiza el efecto de la introducción de nuevas capas ocultas. Al aumentar las neuronas en la capa oculta la predicción mejora levemente, por lo que los autores concluyen que la resolución del problema tiene una dimensionalidad interna de más o menos 5 neuronas. Por otra parte, Garavaglia (1991) ha utilizado una RN perceptrón para predecir ratings. Con una muestra de 797 compañías el acierto global fue del 23% cuando usaba 17 clases y 84% cuando se trataba de 3 clases (grado de inversión, especulativo y pobre calidad crediticia).

Los buenos resultados obtenidos por las RBF en otras disciplinas científicas también se han probado para la evaluación crediticia y su riesgo. West (2000) realiza una comparación de diversas técnicas estadísticas y de algunos SAA, utilizando solicitudes de crédito alemanas y australianas (1000 y 690 datos, respectivamente). Este autor cataloga a la RBF como *modelo superior* (en contraste a una clase de *modelos inferiores*) debido a que presenta mejor desempeño en la clasificación. Para ello, este autor compara las diferencias de los errores (estadísticamente significativas) con el test de McNemar. Las RBF también se han utilizado para la predicción de ratings. Chaveesuk et al. (1999) comparan los aciertos obtenidos de la clasificación de rating (con 6 clases) con RBF, otras dos RN y dos regresiones, concluyendo que las RBF fueron los sistemas automáticos que obtuvieron peor desempeño. Posteriormente Rovira et al. (2004) realizan una aplicación con RBF, pero no la comparan con ninguna otra técnica. En este trabajo se han clasificado entre un 75% y 79% correctamente los ratings (en dos clases) utilizando una RBF, en base a información discretizada con el algoritmo CAIM de Kurgan y Cios (2001). En Lee (2007) se usan RN con 12 diferentes tipos de configuraciones para replicar los ratings de 3017 compañías coreanas clasificadas en 5 clases (desde AAA hasta C, excluyendo la clase D, de fallido) logrando niveles de acierto entre 55% y 60%.

Uno de los últimos estudios que utiliza RN para replicar rating crediticios de compañías es Ahn y Kim (2011), donde se usaron datos de 1295 compañías del año 2002 para replicar 4 niveles de rating (ninguna con fallido). Se usó 5-cv para el 80% de los datos para entrenamiento y validación cruzada (el 20% restante para test). Lo interesante de los resultados de este artículo es que usaron comparativamente RN y SVM junto a dos procedimientos de clasificación que incluían las siguientes variantes: *uno contra uno*, *uno contra todos*, *forward* y *backward*¹⁷. Los niveles de acierto de las RN estuvieron entre el 65,3% y el 68%. Los autores subrayan las bondades de la inclusión de estas variantes tanto para RN como para SVM.

De todas estas investigaciones sólo se puede concluir que, en la tarea de predicción, las RN son tan eficientes como la regresión logística, y, aunque existen excepciones, estas dos técnicas suelen tener mayor nivel de aciertos que el AD, el probit y el modelo de probabilidad lineal.

Árboles de Decisión

Otro tipo de técnicas de IA usadas para fines predictivos en riesgo de crédito son los Árboles de Decisión (DT). De acuerdo a Rossenberg y Gleit (1994), en 1972 en la University of Richmond ya se había desarrollado un DT para construir un modelo de scoring. Posteriormente, Frydman et al. (1985) aplicaba una RPA (un tipo específico de DT) para clasificar y predecir compañías en quiebra, comparándola con AD. En esta oportunidad, en la mayoría de los casos la aplicación con RPA fue más precisa que el AD. En la misma dirección, Galindo y Tamayo (2000) utilizan una CART (otro tipo de DT), junto a dos SAA y probit, para predecir el fallido en créditos hipotecarios mexicanos entre 1995 y 1996. En esta oportunidad, con la técnica CART se cometió un 8% de errores, superando a otras dos técnicas SAA (11% y 15%) y probit (15%).

Contrariamente a estos resultados, los trabajos de Laitinen y Kankaanpää (1999), West (2000) y Shin y Han (2001) indican que las técnicas DT tuvieron peor desempeño que las restantes técnicas utilizadas. En el primero de estos trabajos, la RPA mostró mejores índices de acierto (en comparación con cuatro técnicas estadísticas y una RN) para la predicción de quiebra de compañías finlandesas entre 1986 y 1989, pero en la predicción fuera de la muestra los porcentajes de acierto de la técnica RPA la ubicaron en últimos lugares. Las tasas de errores por predicciones de la RPA a 1, 2 y 3 años antes de la quiebra, fueron del 17% al 42%, en contraste de otras técnicas que obtuvieron entre 8% y 29% de errores. En el trabajo de West (2000), CART erró en un 30% de los casos alemanes y en un 17% de los casos australianos, frente un 23% y 13% de las mejores técnicas de predicción, respectivamente.

¹⁷ En Estadística son ampliamente conocidos los métodos Stepwise, Backward y Forward, los que son procedimientos de selección basados en criterios estadísticos (Landa de Wilks, F de Fisher, etc.) y que han sido incorporados en algunos de los paquetes estadísticos más conocidos como SPSS, BMDP, etc.

Similares resultados obtuvieron Shin y Han (2001) con la utilización de ID3 para clasificar ratings corporativos (en 5 clases) de datos coreanos entre 1991 y 1995. Sin embargo, los aciertos mejoraron significativamente con el uso de una aproximación híbrida de DT con RN: la ID3 obtuvo los errores de mayor magnitud (41%), seguida por las predicciones del AD (40%), y los mejores resultados se obtuvieron con la combinación entre el DT denominado KATETM y la red neuronal Case-Based Reasoning (30% de error).

En Wang y Ma (2011) se usaron diferentes técnicas estadísticas y de IA para análisis crediticio de dos bases de datos chinas; una con 239 compañías y la otra con 132 compañías. Estos autores utilizaron el paquete Weka¹⁸, y en éste, el DT usado fue C4.5 para analizar si las compañías eran riesgosas o no. Los datos cubrieron los años 2006 y 2007. Los resultados con DT fueron los peores del conjunto de técnicas usadas (logit, DT, RN y Boosting¹⁹) para una de las bases de datos; en cambio en la otra base de datos, los niveles de acierto con DT fueron levemente superiores a los obtenidos con logit y similares a los logrados con RN.

Con todos los anteriores resultados no es posible concluir si los Árboles de Decisión son realmente mejores o peores técnicas para predecir y clasificar que las restantes técnicas estadísticas y de IA, más aun cuando existen pocos trabajos que realizan contrastaciones estadísticas para medir las diferencias entre las predicciones.

Sistemas Automáticos de Soporte Vectorial

Respecto del uso de técnicas clasificatorias en el ámbito de riesgo crediticio, en la última década los SVM han tenido un crecimiento significativo. Hasta antes de 2000, los SVM sólo eran utilizados en diversos ámbitos científicos, pero poco en el ámbito financiero. Hoy se utilizan en el reconocimiento y clasificación de imágenes y escritura (Fernández y Viennet, 1999; Zhang, Jin, Yang y Hauptmann, 2003; Justino, Bortolozzi y Sabourin, 2005), y el análisis y clasificación en biomedicina y bioinformática (Goldbaum et al., 2002; Chan, Lee, Sample y Goldbaum, 2002; Cho y Won, 2003), entre algunas áreas. En el ámbito financiero, los SVM se usan con menor frecuencia. No obstante, se han usado en dos áreas de conocimiento financiero: para la predicción de precios y volatilidad bursátil (van Gestel, Suykens, Baestaens, Lambrechts, Lanckriet, Vandaele, de Moor y Vandewalle, 2001; Tay y Cao, 2002; Cao, 2002; Huang, Nakamori y Wang, 2005) y en aplicaciones de riesgo crediticio y detección de fraude. Fan y Palaniswami (2000) las ha utilizado para predecir situaciones de fallido en compañías. Para ello, los autores han utilizado una muestra de 174 empresas australianas (86 con

¹⁸ Weka es un software libre (GNU-GPL) para aprendizaje automático y minería de datos desarrollado en la Universidad de Waikato, N.Zelanda. Indicaciones y software disponibles en <http://www.cs.waikato.ac.nz/ml/weka/>.

¹⁹ Boosting es un SAA del tipo meta-algoritmo de aprendizaje supervisado, basado en el planteamiento de Kearns (1998). Mayores detalles en Freund y Schapire (1997).

fallido), y aplican modelos predictivos de Altman (1968), Ohlson (1980), Linconl (1982) y uno propio (con las variables de los trabajos de estos tres autores más otras 5 adicionales). Estos autores incluyeron tres técnicas para comparar los resultados obtenidos con la SVM: AD, RN multiperceptrón y Learning Vector Quatization (un tipo de IBL). En los 4 modelos aplicados, la SVM (con 71% de aciertos) consiguió los mejores resultados predictivos (versus el 65%, 67% y 69% de aciertos, de las restantes técnicas, respectivamente). Con las variables utilizadas en Linconl (1982), Ohlson (1980) y la propia propuesta de Fan y Palaniswami (2000), la peor técnica predictiva fue el AD (62%, 65% y 61% de aciertos, respectivamente), mientras que al utilizar las variables de Altman (1968), la peor técnica predictiva fue Learning Vector Quatization (62% de aciertos). Otro trabajo en que se compara los resultados de SVM con los obtenidos con otras técnicas es el de Baesens et al. (2003), quienes clasifican los créditos de instituciones financieras de Alemania, Australia, Benelux (Bélgica, Holanda y Luxemburgo) y el Reino Unido. Para ello, contaron con datos de 39.003 casos y utilizaron técnicas estadísticas y SAA. Las técnicas que tuvieron mayor acierto fueron las RN y los SVM, seguidas por la regresión logística y el AD lineal (por encima del AD cuadrático). Las que tuvieron peor desempeño fueron los DT y las técnicas k-NN. Otros trabajos donde se han utilizado SVM para la predicción de quiebras corporativas son los de Härdle et al. (2004, 2005), con una base de datos de 84 compañías de EUA (42 de ellas en quiebra entre 2001 y 2002). En estos trabajos se predicen correctamente el 62% de las compañías en quiebra con la SVM, y logran un 60% de acierto con AD. De acuerdo con estos autores, la diferencia entre ambas predicciones no es estadísticamente significativa al 5%, por lo que, en este caso, la SVM no podría ser considerada como un clasificador superior al AD.

Además, en evaluación de riesgo crediticio, dentro de los últimos cinco años, se han realizado estudios acerca de la bi-clasificación de empresas no financieras, ya sea a través de la definición de fallido o bien de su calidad crediticia (Huang, Chen y Wang, 2007; Bellotti y Crook, 2009; Danenas, Garsva y Gudas; 2011). Ravi, Kurniawan, Thai y Kumar (2008) usan datos de la condición crediticia de 1000 bancos de EUA entre los años 1991 y 1993 para bi-clasificarlas. Para esto utilizan diversas RN, una DT, una SVM y una FL. Los peores desempeños evaluados, con los niveles de acierto global, usando 10-cv, fueron obtenidos con la FL y 2 RN; en cambio, los mejores desempeños fueron obtenidos con la SVM y una RN híbrida (combinada con un kernel de análisis de componentes principales). En estos estudios, el desempeño de los SVM fue sobresaliente. En ninguno de estos estudios, para los diferentes grupos de muestras y configuraciones, los SVM fueron mal evaluados. Los kernels con mejores niveles de eficiencia han sido los gaussianos y los polinomiales de grado 2.

Respecto de la multclasificación ordinal con SVM en riesgo crediticio, también se han realizado estudios sobre la concesión de crédito con tarjetas bancarias. En Kou, Peng, Shi y Chen (2006) se ha incluido distintas técnicas para clasificar la condición crediticia ordinal de clientes alemanes, australianos y japoneses de tarjetas de crédito. Usando 10-cv, los resultados mejor evaluados se

obtuvieron con SVM. En este estudio se usaron 2 y 3 clases para clasificar a los clientes de tarjetas de crédito.

La evaluación de rating de instituciones bancarias y financieras ha sido uno de los puntos que ha llamado la atención en los últimos 5 años. Probablemente por ello y por el nivel de eficiencia de los SVM es que estudios, como en el de Jilani y Burney (2008), comienzan a utilizarse para la réplica de rating. Estos autores utilizan una SVM combinada con una FL para clasificar datos de 100 instituciones financieras en 5 categorías de riesgo. El nivel de acierto global es del 83%. Es muy interesante que en este trabajo se hayan logrado crear 5 clases difusas con FL de una entrada de 15 categorías de rating crediticio. El kernel usado para la SVM fue gaussiano.

Por otra parte, Bellotti, Matousek y Stewart (2011a) replican el rating de Fitch de 517 bancos internacionales, logrados entre 2000 y 2006. Para ello, usan 9 clases de rating y aplican logit, probit y SVM, obteniendo los siguientes mejores niveles de acierto en el subconjunto de test: 38,4%, 39,3% y 44,6%, respectivamente. El ajuste de los parámetros de la SVM se realizó con 10-cv. Los autores además recalcan la importancia de incluir la variable país al modelo para mejorar la eficiencia en la réplica cuando se usan datos de muchos países que tienen realidades heterogéneas. Esto queda aún más evidente en otro artículo de los mismos autores (Bellotti, Matousek y Stewart, 2011b). Un último estudio de réplica de 86 ratings de Moody's (entre 2003 y 2009) de instituciones bancarias en Turquía es el de Ögüt, Goğanay, Ceylan y Aktaş (2012), donde utilizan regresión múltiple ordinal y AD, RN y SVM. Para ello, los autores usan 6 clases de rating y obtienen los siguientes niveles de acierto con 3-cv: regresión logística 62,8%, AD 65,1%, RN 62,8% y SVM 65,1%.

En la réplica de ratings de compañías con SVM el primer trabajo fue el desarrollado por Moro (2004). En su tesis utilizó datos de 42 compañías de EUA con los ratings de 1998 y 1999. Con estos datos Moro realizó simulaciones de datos e hizo comparaciones de la eficiencia de bi-clasificación entre diferentes SVM y AD. Para comparar los resultados clasificatorios usó los niveles de acierto y la curva ROC. Los niveles de acierto de los SVM (65% hasta 100%) fueron muy superiores a los de la AD (1% hasta 62%). En otro estudio, Huang, Chen, et al. (2004). utilizan dos conjuntos de datos de bonos corporativos con sus respectivos ratings (de 5 clases): uno con 74 casos taiwaneses obtenidos entre 1998 y 2002; y otro con 255 casos estadounidenses obtenidos entre 1991 y 2000. Se eligieron dos conjuntos de variables financieras para cada base de datos, utilizaron tres técnicas clasificatorias (regresión logística, RNRP y SVM) y dos metodologías de validación tipo cross-validation. La técnica que obtuvo mejores predicciones para todos los conjuntos de datos y variables fue la SVM (entre 77% y 80% de aciertos) y la que obtuvo peores predicciones fue la regresión logística (entre un 70% y 77% de aciertos). Cabe subrayar los problemas ya expuestos anteriormente, relacionados con los datos usados en este estudio.

Posteriormente, Lee (2007) utiliza una base de datos de 3017 compañías coreanas para replicar el rating. Los datos cubren desde 1997 a 2002 y utilizan 5 clases de rating (sin fallido) y comparan el desempeño de réplica con AD, SVM, 12 RN diferentes y una Case-Based Reasoning²⁰. Se usan diferentes metodologías de separación de muestras para cada técnica clasificatoria: validación cruzada, entrenamiento-test y entrenamiento-validación-test. En este caso, los mejores desempeños se obtuvieron con SVM (67% en el test) y CBR (63,4% en el test). Los autores encontraron que las diferencias de los porcentajes de acierto eran estadísticamente significativas en los siguientes niveles (se indican los p-value): SVM-RN 0,002, SVM-AD 0,000, CBR-AD 0,064 y SVM-CBR 0,096.

Otra réplica de rating de compañías la llevan a cabo Ahn y Kim (2011) con datos de 1295 empresas coreanas del año 2002. Para ello usan 4 clases de rating y 14 ratios financieros. Los autores inician el conjunto de datos con 39 variables, pero sólo seleccionan 14 de ellas, basándose en el test-t para medir el grado de contribución a la explicación a la varianza del rating. Las técnicas usadas para replicar en este estudio son RN y SVM, pero agregan la alternativa de incorporar previos procedimientos de clasificación y selección (uno contra uno, uno contra todos, forward y backward), y esto ayuda a mejorar levemente los niveles de acierto de estas SAA. Usando 5-cv sobre un 80% de los datos para entrenar y 20% para validar, los niveles de acierto máximo llegan al 68% con RN y 73% con SVM.

Métodos Basados en la Vecindad

Otro de los Sistemas de Aprendizaje Automático utilizados en el contexto del análisis del riesgo crediticio son los Métodos Basados en la Vecindad (IBL). Una de las primeras aplicaciones de IBL en problemas de riesgo crediticio es la llevada a cabo por Tam y Kiang (1992), quienes usan dos variantes sencillas: 1-NN y 3-NN. También utilizan AD, regresión logística, ID3 y dos RNRP para predecir la quiebra bancaria a uno y dos años antes del suceso de fallido. Los resultados de la predicción indican que 1-NN y 3-NN fueron las peores técnicas predictivas (desde el 20% al 30% de error), seguidas por ID3 (desde 19% al 23% de error). Las mejores predicciones se obtuvieron con las RNRP (con errores desde el 11% al 18%).

En esta misma línea de conclusiones, los trabajos de Baesens et al. (2003) y Galindo y Tamayo (2000), concluyen que, para los conjuntos de datos que ellos utilizaron, las k-NN no predicen mejor que otras técnicas usadas. Ambos artículos se basan en datos de instituciones financieras (europeas, australianas y mexicanas) para clasificar créditos. Galindo y Tamayo (2000) utilizan una CART, una RN, una k-NN y un probit, para predecir el fallido de créditos hipotecarios mexicanos. En esta oportunidad, con la técnica k-NN se cometió un 15% de errores frente al 8% de la CART, el 11% de la RN y el 15% de

²⁰ Esta es un tipo de SAA heurístico para la búsqueda de soluciones basado en la estructura de resolución de problemas similares anteriores.

probit. Por otra parte, Baesens et al. (2003), clasifican créditos de instituciones financieras europeas y australianas, utilizando técnicas estadísticas y SAA, y concluyen que las técnicas que tuvieron peor desempeño fueron las DT y las técnicas k-NN. En cambio, las técnicas que tuvieron mayor acierto fueron las RN y los SVM.

Otro trabajo en el que se han usado dos tipos de IBL es West (2000). Este autor también indica que el desempeño de estas técnicas conlleva pobres niveles de aciertos. En su estudio para créditos de instituciones financieras ha utilizado una k-NN que arroja resultados predictivos levemente mejores que otras técnicas; sin embargo, la LVQ tiene elevados niveles de errores en las predicciones. West (2000) utiliza dos bases de datos y los resultados son los siguientes: i) las predicciones con los datos alemanes realizadas con una k-NN y una LVQ son las peores del conjunto (32% de error de la k-NN y de la LVQ, frente al 24% de error obtenido con la regresión logística), y ii) usando una base de datos australiana, las predicciones obtenidas con la k-NN se situaron en sexto lugar (de un total de 10), ya se erraron el 14% de las predicciones, mientras que las predicciones con la LVQ se situaron en la novena posición (con un 17% de error). La técnica con mejores predicciones con los datos australianos logró un 12,8% de errores y la peor un 24,6%. West (2000) también comparó la significancia que existía en las diferencias entre las tasas de error entre todas las técnicas. En ambos conjuntos de datos, LVQ es calificada como *modelo inferior* por su pobre desempeño frente a las restantes. En cambio, la k-NN es un *modelo superior* con los datos australianos y un *modelo inferior* con los datos alemanes.

En la clasificación con LVQ de ratings existen dos trabajos que, al comparar los niveles de acierto, entregan señales opuestas. El trabajo de Chaveesuk et al. (1999) perfila a la LVQ como la peor técnica en la tarea de clasificar rating (en 5 clases), siendo superada por dos regresiones (una logística y otra lineal), una RBF y una RNRP. En cambio, Kim, Weistroffer y Redmond (1993) plantean que la LVQ utilizada para su conjunto de datos, obtuvo los mejores niveles de aciertos, al compararlos con una RBF y tres técnicas estadísticas. Concretamente, los niveles de acierto son del 55% con la LVQ, del 43% con la regresión logística, del 36% con regresión lineal y con AD, y del 31% con RBF.

Algoritmos Genéticos

Respecto de técnicas de predicción de Softcomputing, hasta la fecha, se han utilizado en problemas de riesgo crediticio algunas de estas técnicas junto a RN. Back et al. (1996) han usado Algoritmos Genéticos, sobre la base de una RN, para predecir la quiebra corporativa. Para ello utilizaron una base de datos de 37 compañías finlandesas quebradas entre 1986 y 1989, generando predicciones para 1, 2 y 3 años antes del fallido. Se compararon los aciertos de estas predicciones con los obtenidos con regresión logística y con AD. En este artículo se han generado 9 predicciones diferentes: 3 por cada técnica y 3 por cada año de anticipación a la quiebra. Cabe destacar que en el AD se utilizó el método stepwise, basado en el lambda de Wilks (Hair et al., 1999), para seleccionar las variables que

ingresaban al modelo, mientras que la selección de las variables en el AG se realizó con una RN, por lo que las variables seleccionadas fueron diferentes. A pesar de que en la regresión logística se utilizó el mismo método de selección de variables que en el AD, en la regresión logística las variables elegidas fueran distintas a las usadas con AD. En consecuencia, es necesario comparar con cautela los resultados de predicción, ya que para cada técnica se utilizaron distintos conjuntos de variables. De estos resultados, la técnica que predijo con menores errores un año antes las quiebras fue el SAA híbrido de RN con AG (2,7% de error), frente a los obtenidos con regresión logística (3,5%) y con AD (14,9%). Similar situación ocurre con las predicciones a 3 años, donde la mejor predicción se obtuvo con la máquina híbrida (16,2%), seguida por la regresión logística (25,7%) y el AD (27,0%). En la predicción a dos años el AD fue superior (22% de error) al híbrido (27%) y a la regresión logística (28%). Por otra parte, Kingdon y Feldman (1995) han usado Algoritmos Genéticos para inferir reglas que ayudan a predecir quiebras corporativas usando su información financiera. En promedio, el AG produjo resultados un 15% mejores que los modelos estadísticos.

Lógica Difusa

En otra línea de investigación, Su y Chen (1980) proponen el uso de FL para representar varios factores lingüísticos, basándose en datos reales proporcionados por bancos de Taiwán. Luego, Berenji y Khedkar (1992) han propuesto *redes neuronales difusas*, un híbrido que utiliza reglas de FL en una RN, y Malhotra y Malhotra (1999) han propuesto el uso de sistemas expertos, RN y FL para reducir la complejidad y mejorar la exactitud en la aprobación del crédito. Sin embargo, estos autores no dieron ningún algoritmo o detalles de posibles aproximaciones. Rast (1997) presenta un esquema para utilizar una RN difusa para pronosticar series temporales de precios (acciones, bonos o commodities) y para otorgar rating crediticio a clientes bancarios. Rast plantea que esta aproximación sólo sería útil con una gran cantidad de datos disponible, pero no desarrolla ninguna de las dos aplicaciones. Piramuthu (1999) propuso el uso de una RN y una RN difusa para mejorar las decisiones de evaluación de crédito, sin ofrecer una aplicación comparativa ni resultados empíricos. Todos estos trabajos, exceptuando el de Su y Chen (1980), enfatizan que el aprendizaje de una RN consume mucho tiempo de proceso y necesita una gran base de datos. Estos requerimientos pueden ser impedimentos por los que no aplican empíricamente sus propuestas. Por último, Syau et al. (2001) proponen el uso de una representación lingüística difusa para rating internos (sin desarrollar su aplicación total) y usa datos de rating bancarios de Taiwán para ilustrar comparativamente algunos resultados obtenidos en Su y Chen (1980). De esta comparación, Syau et al. (2001) manifiestan discrepancias en las estimaciones de los puntajes de corte obtenidos en Su y Chen (1980), sin llegar a clasificar o predecir ratings o indicadores de la calidad crediticia de empresas.

En resumen, no existen claras y contundentes conclusiones de cuál es la técnica más apropiada para la predicción de problemas crediticios y la clasificación de rating. Como se puede desprender de lo

comentado en esta sección y de lo ilustrado en la Tabla 23 se puede advertir que los mayores éxitos y niveles de eficiencia de cada una de las técnicas dependen (a) de los datos utilizados, (b) de las variables que incluyen en el modelo y (c) del período que abarca el estudio. Aun así, considerando que pueden existir disparidades en la determinación de una técnica que sea superior a las restantes, es posible percatarse que las técnicas de IA son levemente superiores a las estadísticas. La Tabla 24 expone un resumen comparativo de algunos estudios predictivos relacionados con riesgo de crédito, con la intención de que sea más evidente qué tipo de técnica tuvo el mejor desempeño desde su propia muestra de datos. Concretamente, los valores que se exhiben para cada estudio, indican cuánto es la distancia porcentual que se logró con cada técnica si es comparada con la mejor de las predicciones. Un porcentaje bajo (o igual a cero) indica que dicha técnica tuvo un buen (o el mejor) nivel de acierto. Por al contrario, un alto valor indica que la técnica no tuvo buenos niveles de predicción. Por ejemplo, en Kaplan y Urwitz (1979) con probit se logró un 50% de aciertos y un 55% con un modelo de probabilidad lineal, por ello, en la tabla indica que con probit hay una diferencia de 5% respecto de la mejor técnica de predicción. En esta tabla, se puede apreciar que, en términos medios, las técnicas de IA tienen mejor desempeño que las técnicas estadísticas.

Tabla 24. Diferencias entre los porcentajes de acierto de cada técnica y la mejor técnica de predicción

Referencia	Técnicas Estadísticas				Técnicas de Inteligencia Artificial					
	AD	PL	P	RL	RN	DT	SVM	IBL	AG*	FL*
Kaplan y Urwitz (1979)		0%	5%							
Fryedman et al. (1985)	15%					0%				
Dutta y Shekhar (1988)				23%	0%					
Utans y Moody (1991)				8%	0%					
Tam y Kiang (1992)					0%	7%		14%		
Han y Jhee (1993)	25%				0%					
Kim et al. (1993)	19%	19%		12%	24%			0%		
Back et al. (1996)	6%			4%						0%
Maher y Sen (1997)		8%			0%					
Kwon et al. (1997)	12%				0%					
Chaveesuk et al. (1999)		7%		2%	0%			18%		
West (2000)				0%		1%		10%		
Galindo y Tamayo (2000)			7%		3%	0%		7%		
Fan y Palaniswami (2000)	6%				4%		0%	2%		
Shin y Han (2001)	6%				4%	7%			0%	
Baesens et al. (2003)	3%			0%	1%	8%	2%	5%		
Campos et al. (2004)	0%						2%			
Huang et al. (2004)				5%	2%			0%		
Härdle et al. (2005)	2%							0%		
Rovira et al. (2005)	4%			0%				7%		
Kou, Peng, et al.(2006) †	22%					22%	0%			
Ravi, Kurniawan et al.(2008)					0%	17%	2%			
Lee (2007)	8%				7%		0%			
Ahn y Kim (2011)					7%		0%			
Wang y Ma (2011)				1%	0%	1%				
Öğüt, Goğanay et al.(2012)	0%			2%	2%		0%			
	AD	PL	P	RL	RN	DT	SVM	IBL	AG*	FL*
Nº de veces que es la mejor	2	1	0	3	9	2	7	1	1	1
Nº de veces que es la peor	8	1	2	4	3	5	2	4	0	0
Nº de veces en comparación	14	4	2	11	18	9	11	7	1	1
Distancia a la mejor (mediana)	6%	8%	6%	2%	1%	7%	0%	7%	0%	0%

NOTAS: (†) En Kou, Peng, et al.(2006) se han usado distintas bases de datos, y aquí sólo se han mostrado los resultados de la base de datos alemana, que no difiere sustantivamente de las restantes.

Este listado sólo incluye trabajos donde se han utilizado dos o más técnicas con mismas bases de datos. El acierto utilizado es el global. En caso de que existieran modelos de un mismo tipo de técnica que tuviesen grandes diferencias se ha elegido el que tenía mejor nivel de aciertos, en caso contrario se promediaron los niveles de aciertos. Las predicciones en cursiva tanto de AG* y FL*, en realidad son híbridos con RN. Lo mismo sucede con el modelo IBL usado por Kim, Weistroffer y Redmond (1993). La *distancia a la mejor* técnica es la mediana de los valores de la parte superior de la tabla. Abreviaciones no explicadas anteriormente: **PL** es el modelo de probabilidad lineal; **P** es modelo probit; **RL** es regresión logística.

Fuente: Elaboración propia.

Las cuatro técnicas que obtuvieron menor valor de este estadístico construido y presentado en la Tabla 24 son las RN, la SVM y la regresión logística (se han descartado los resultados de FL y AG porque en realidad los modelos utilizados en estas investigaciones son híbridos con RN). La distancia mediana de estas 3 técnicas no superó el 2%. Es interesante observar que en 9 de 18 investigaciones las RN fueron las técnicas con mayores niveles de acierto y que los SVM lo fueron en 7 de 11. En contrario, cada vez que se usó probit ésta fue la que tuvo peor desempeño (2 veces de 2), seguida por las IBL (con 4 veces de 7) y el DT (con 7 veces de 9).

3.6 La propuesta para replicar el rating en esta tesis

De acuerdo a la revisión de la literatura para cumplir los objetivos propuestos en esta tesis, al igual que en el capítulo anterior, el autor propone la siguiente metodología para los distintos aspectos del proceso de réplica de rating:

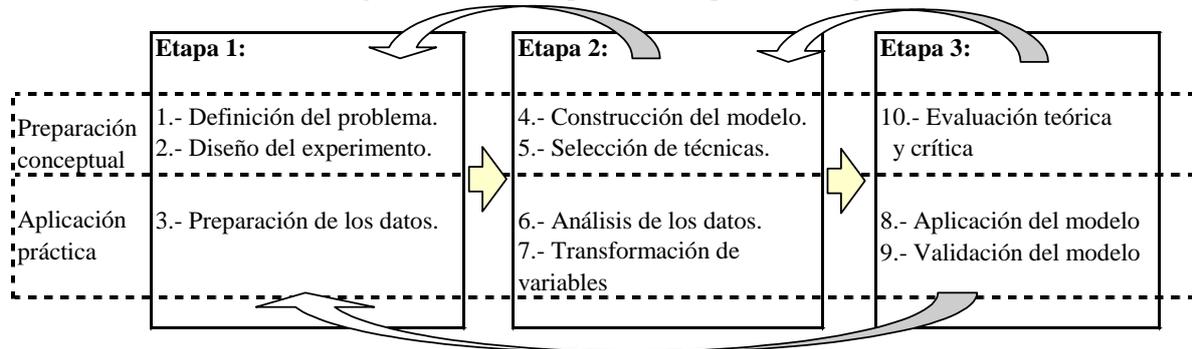
- ✓ Respecto de las transformaciones de las variables, se consideran dos aproximaciones:
 - *Mantener las variables sin transformación alguna*: la transformación suele realizarse para disminuir los efectos del incumplimiento de supuestos estadísticos, por lo tanto, lo que se desea es inducir el peso de este incumplimiento en los resultados de las técnicas estadísticas al no realizar la transformación de las variables. Este no debería significar un problema para los SVM, debido a que, de una manera natural, los kernels realizan las transformaciones necesarias en los distintos hiperplanos óptimos.
 - *En un segundo experimento, discretizar las variables que explican el rating*: con esto se pretende evaluar el impacto de la discretización de variables sobre el entrenamiento con SVM y comparar su efecto con la réplica de los datos sin discretizar. Como ya se ha discutido en este capítulo, en la mayoría de los casos que se han usado datos discretizados, se ha perdido de información. Por lo tanto, hay que evaluar si realmente ésta se pierde y si es así, cuánto se pierde. Dada la revisión se sugiere el uso de CAIM*.

- ✓ Respecto al diseño experimental, se decide usar la muestra de datos separadamente en dos partes. La primera parte serviría para el entrenamiento y para validación cruzada con 10 carpetas. La segunda parte de los datos se usaría exclusivamente para validar la réplica fuera del conjunto de entrenamiento. Este procedimiento se decide repetirlo 30 veces y promediar sus estadísticos de comparación, de tal manera que éstos sean lo suficientemente robustos. Además de lograr un adecuado diseño experimental, con esto se logra concentrar la atención en dos objetivos:
 - Comparar los resultados entre las técnicas.

- Evaluar el desempeño de las técnicas fuera de la muestra de entrenamiento o ajuste. Con esto se centra la atención en la capacidad que tienen las técnicas en la generación del modelo elegido.
- ✓ Para evaluar el desempeño o bondad de los resultados, se adopta el uso de matrices de confusión y de tasas de acierto y error, evaluando los tipos de errores (sobreevaluación y subevaluación) y midiendo cuán lejos de la diagonal se encuentran dichos errores.
- ✓ De acuerdo a las recientes evidencias de réplica de rating, se decide hacer dicha tarea predictiva con 5 a 8 clases agrupadas de rating. Con esto se pretende que exista una buena granularidad y que la categorización sea comprensible por el usuario.
- ✓ La réplica será realizada de una manera comparativa para evaluar el desempeño de diversas técnicas, mediante validación dentro y fuera de la muestra.

Además de estas consideraciones, y de acuerdo a la revisión de la literatura, se decide que la tarea de réplica de rating sea llevada a cabo en tres etapas, tal y como lo expone la Figura 9.

Figura 9. Pasos en el proceso de réplica de rating.



Fuente: elaboración propia.

En esta figura se pone de manifiesto que la réplica corresponde a un proceso de pasos secuenciales, ordenados en tres etapas. Cuando se confirma la veracidad o la aplicación correcta de un paso se continúa con el siguiente. En caso contrario, el investigador debe retroceder a la(s) etapa(s) anterior(es) y realizar las acciones correctivas que le permitan superar el obstáculo. El último paso consiste en evaluar la bondad de la predicción. En caso de que ésta no sea razonable el investigador deberá retroceder e indagar los motivos que llevan a dicha situación. Cada uno de estos pasos puede ser entendido desde una perspectiva más conceptual, o bien, más práctica. De ahí que en la figura aparezcan los pasos separados por líneas punteadas.

En la Figura 9 se puede observar la importancia de la preparación y análisis de los datos. Esta es la tarea que se pretende cumplir en el siguiente capítulo de esta tesis.

3.7 Resumen

El objetivo de esta tesis es realizar la réplica de rating de agencias (como S&P y Moody's) y evaluar los resultados y las implicaciones que se produzcan de esta tarea. Hasta hoy las técnicas estadísticas son un grupo de herramientas ampliamente aceptadas para llevar a cabo la tarea de réplica. Incluso, las redes neuronales han ido ganando el respeto de la comunidad científica y de los profesionales de la práctica financiera, sobre las cuales existe una amplia gama de referencias en aplicaciones financieras y crediticias. Sin embargo, el uso del análisis discriminante y las técnicas de regresión adolecen de problemas serios que se relacionan con los supuestos que les permiten realizar sus construcciones y, por lo tanto, son cuestionables los resultados que se puedan obtener con estas técnicas. Es lógico pensar que si son violados los supuestos que permiten el uso de estas técnicas estadísticas, entonces la generalización del modelo de réplica es más riesgosa. En este sentido, tanto en la banca e industria financiera como en los trabajos de investigadores y organismos reguladores, buscan técnicas y modelos alternativos que entreguen mayor confiabilidad para evaluar el riesgo crediticio.

La mayor confiabilidad en el uso de modelos predictivos y clasificatorios, y el deseo de incrementar el nivel de aciertos ha generado la necesidad de incursionar en nuevas técnicas. Entre las técnicas de IA, algunos SAA han ocupado el tiempo y recursos de académicos y profesionales de la industria financiera. Esta orientación hacia los SAA se debe a que: (i) éstos son modelos teóricamente más robustos a problemas de los datos y del entorno, sin la necesidad que éstos deban cumplir con cualidades estadísticas; (ii) algunas de estos SAA tienen un gran poder de generalización y han probado tener bastante éxito en tareas predictivas; y (iii) el coste, capacidad y velocidad del procesamiento de datos es día a día menos prohibitivo, permitiendo el uso de complejas construcciones de IA.

Para realizar la tarea de réplica de ratings es necesario elegir o considerar las opciones que existen en al menos los siguientes cuatro cinco: (a) elegir la técnica clasificatoria más adecuada en cuanto a sus costes y beneficios; (b) decidir si es pertinente la transformación a las variables; (c) elegir la técnica de validación que permita realizar el diseño de experimento más adecuado para obtener resultados más precisos y veraces; (d) elegir las herramientas que permitirán realizar las mediciones de la bondad de la tarea predictiva; y (e) seleccionar el conjunto de datos que servirá al investigador para los propósitos finales de la réplica.

Cada uno de estos cinco elementos ayuda al investigador a replicar los ratings más acertadamente. Además, algunos de ellos se encuentran muy relacionados y su modificación puede causar mayor impacto en los niveles de acierto que los provocados en los restantes. Por este motivo, en este capítulo se han descrito estos elementos en forma sintética, centrando la atención en la tarea de clasificación de ratings. En este capítulo se han revisado Sistemas de Aprendizaje Automático de más reciente uso para

la evaluación del riesgo de crédito, exponiendo las aplicaciones en compañías y, particularmente, para la clasificación en rating de agencias externas. La literatura en esta área del conocimiento es amplia en algunos tipos de técnicas y nueva en otros. La implementación de SVM, Lógica Difusa o Algoritmos Genéticos, son algunas de las técnicas más recientes y de las cuales se esperan avances en los siguientes años. Para tener una perspectiva más general de todas las técnicas clasificatorias que se han expuesto en este capítulo, la Tabla 25 muestra las ventajas y desventajas más relevantes de cada una de estas técnicas.

Tabla 25. Ventajas y desventajas de las técnicas de clasificación presentadas en este capítulo.

Principales y más relevantes:		
Técnica	Ventajas	Desventajas
AD	simplicidad y fácil comprensión	sus supuestos suelen no cumplirse
Prob.Linear	simplicidad y fácil comprensión	sus supuestos suelen no cumplirse
Probit	simplicidad y fácil comprensión	algunos supuestos suelen no cumplirse
Logit	simplicidad, fácil comprensión y mayor precisión	algunos supuestos suelen no cumplirse
RN	flexibilidad, uso sin supuestos y permite modelar relaciones complejas	difícil interpretación del entrenamiento
DT	flexibilidad, uso sin supuestos y fácil comprensión	la técnica es sensible a los costes y no permite límites de clases difusas
SVM	uso sin supuestos, capacidad de generalización, reducción de dimensionalidades y asegura óptimos globales	difícil interpretación del entrenamiento
IBL	uso sin supuestos	difícil interpretación del entrenamiento, no asegura óptimos globales
AG	uso sin supuestos y busca óptimos globales y soluciones no especificadas	difícil interpretación del entrenamiento y rigidez en su diseño
FL	uso sin supuestos y permite límites borrosos en las clases	difícil interpretación del entrenamiento

En esta tabla se puede observar que todos los SAA expuestos en este capítulo gozan de la capacidad de clasificar sin la necesidad de supuestos tanto en las variables como en sus relaciones. Esta es justamente una importante desventaja de las técnicas estadísticas. Pero su principal ventaja es la facilidad en su interpretación y la simplicidad de su formulación. Justamente la mayor dificultad que enfrentan la mayoría de los SAA.

También se han presentado en este capítulo algunas de las transformaciones más usuales a las variables, las técnicas de validación y las metodologías de cuantificación de la bondad en problemas de riesgo crediticio. Se ha procurado especial énfasis en aquellas tareas que se relacionan con la réplica de ratings.

Capítulo 4. La Muestra de Datos

En este capítulo se presenta un conjunto de datos de rating corporativos emitidos por Standard & Poor's (S&P) y aquellas variables relacionadas con dicho rating. El tamaño de la muestra está condicionado por el proceso de vínculo de los ratings con las compañías existentes en Worldscope. Este conjunto de datos de rating es el que se usa para la tarea de replicarlos. Por lo tanto, lo que se expone en este capítulo se describen estos ratings corporativos y las empresas vinculadas. También se exponen los resultados de la evaluación de la influencia de los missing values y finalmente la depuración final de la muestra propuesta por el autor de la tesis.

Esta muestra incluye el rating (en 22 clases) de 1177 compañías industriales, comerciales o que presten servicios, con la última calificación crediticia del 2002 emitida por S&P para cada compañía. Concretamente, se ha usado el rating de largo plazo en moneda local. La clasificación y nomenclatura va desde AAA (la mejor calificación crediticia) hasta D (la peor). A esta distribución de datos se le llamará en adelante rating de nivel 1. A su vez, los ratings también se han agrupado en 7 clases: AAA y AA, A, BBB, BB, B, C y D; que en adelante se les llamará rating del nivel 2. La definición de cada clase de rating se encuentra en la Tabla A 4 del Anexo C y en la Figura A 1 del mismo Anexo está la correspondencia entre clases de los niveles 1 y 2 de rating. La distribución de los ratings se expone en la Tabla 26, donde se observa que el 71% de los datos se concentra entre las clases BBB y B, y en las clases AAA, AA+, CCC-, CC y SD hay muy pocos ratings emitidos (menos de 10 casos por clase). La distribución respecto de BB+ es bastante simétrica. Esta concentración en rating de emisores corporativos es relativamente común en los estudios de calificaciones crediticias (Galil, 2003; Standard & Poor's, 2006).

Tabla 26. Distribución de rating de la muestra por país y grado de riesgo crediticio.

C. país	Rating en 22 clases de calificación crediticia (ordenadas de mayor a menor)																				Total				
	AAA	AA+	AA	AA-	A+	A	A-	BBB+	BBB	BBB-	BB+	BB	BB-	B+	B	B-	CCC+	CCC	CCC-	CC			SD	D	
Austria			1																				1	0,1%	
Belgium						1																	1	0,1%	
Canada	1	1				5	8	12	12	11	11	1	7	5	3	3	1	1					2	84	7,1%
Denmark							1																1	0,1%	
Finland							1	2	1	1													5	0,4%	
France			2		3	1	4	7	5	3			4	1									30	2,5%	
Germany				2	2			2	4		1	1											12	1,0%	
Greece								1															1	0,1%	
Italy			1		1				1														3	0,3%	
Japan	1	1	1	12	1	4	2	1		2	1												26	2,2%	
Luxembourg																		1					1	0,1%	
Netherlands					1	3	2	1			1			1									10	0,8%	
Norway					2	1			1														4	0,3%	
Portugal					1																		1	0,1%	
Spain					1	1				1													3	0,3%	
Sweden					2		3	3			1			1									9	0,8%	
Switzerland							1		1														3	0,3%	
United Kingdom			1	2	8	5	6	13	11	6	2	1	1		1	1						1	60	5,1%	
United States	6		10	8	34	60	49	55	99	81	60	94	113	88	66	28	19	12	2	5	3	30	922	78,0%	
Total Nivel 1	8	2	15	25	53	80	79	98	136	106	77	101	121	95	70	32	20	14	2	6	4	33	1177		
Rating Nivel 2	AAA y AA			A			BBB			BB			B			C			D						
Total Nivel 2	50			212			340			299			197			42			37			1177			

En general, se ha construido esta muestra de datos evitando que ésta no adolezca de problemas de sesgo y que con la captura de los datos, la réplica permita la generalización de los resultados a otras empresas que coticen en bolsa, que desarrollen sus actividades en países desarrollados, con mercados bursátiles desarrollados, y que no pertenezcan a sector financieros o de seguros (Heckman, 1979; Little y Rubin, 1986; Glasserman y Li, 2004). Siguiendo estos criterios la muestra contiene compañías pertenecientes a Estados Unidos, Canadá, Japón y países de Europa. Para incluir países europeos en la muestra los criterios fueron los siguientes: a) su ubicación geográfica, b) la clasificación del ingreso económico del año 2002 realizado por el Banco Mundial, c) nivel de deuda externa clasificada por el Banco Mundial, c) la pertenencia o no a la OECD según el Banco Mundial, e) pertenencia o no a la Comunidad Económica Europea²¹ y tamaño del mercado (en función del número de compañías listadas por la fuente de los datos Worldscope de Thomson Financial). La fecha de cierre para la obtención de estos factores fue el 31 de diciembre de 2002. Con ello, las compañías de la muestra se ubican en los siguientes países europeos: Alemania, Austria, Bélgica, Dinamarca, España, Finlandia, Francia, Grecia, Italia, Luxemburgo, Noruega, Países Bajos, Portugal, Reino Unido, Suecia y Suiza. Todos los datos, excepto la información del rating, fueron proporcionados por Thomson Financial, a través del paquete computacional Datastream Advance 3.5²². De este proceso se tiene que el 78% de los datos son de compañías de EUA, 7% de Canadá, 5% del Reino Unido, 2,5% de Francia, 2,2% de Japón y el resto 5% de otros países europeos.

La exclusión de compañías de la industria financiera y de seguros se debe a que sus actividades, su estructura financiera y, por lo tanto, la información que se puede obtener desde sus registros contables es muy diferente a las restantes compañías. Su inclusión causaría graves problemas en los datos provocados por ausencia de datos o ratios inconsistentes con los aquellos de las otras compañías. Las compañías están distribuidas en 9 sectores industriales clasificados por FTSE Group (FTSE, 2003), listados en la Tabla A 5 del Anexo C. La mayor concentración de datos de rating se encuentra en el sector *CYSER (Cyclical Services)* con el 22% de los datos. Los restantes grupos sectoriales tienen similares tamaños, que van del 7% al 14% del total (ver Tabla 27). Mayores antecedentes de los subsectores industriales que conforman el índice sectorial se encuentra en la Tabla A 5 del Anexo C. La distribución de compañías con rating por industria en los diversos países es relativamente similar a la distribución global, aunque la excepción está en la mayor concentración de empresas canadienses con rating en el sector *RESOR* y *BASIC*.

²¹ Información acerca de estos cinco primeros factores están disponibles en World Bank (2003).

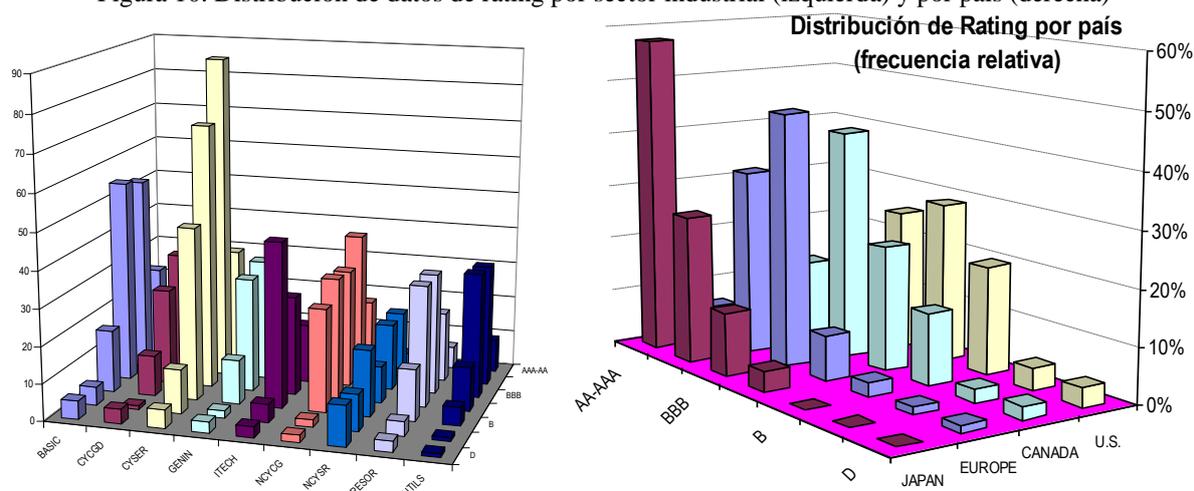
²² Datastream Advance 3.5 es propiedad de Datastream International Limited y de Thomson Financial.

Tabla 27. Distribución de datos por países y sector industrial

Pais	Código de sector industrial (C_indc3)									Total	%	%acum.
	BASIC	CYCGD	CYSER	GENIN	ITECH	NCYCG	NCYSR	RESOR	UTILS			
AUSTRIA									1	1	0%	0%
BELGIUM	1									1	0%	0%
DENMARK							1			1	0%	0%
GREECE									1	1	0%	0%
LUXEMBOURG				1						1	0%	0%
PORTUGAL									1	1	0%	1%
ITALY								1	2	3	0%	1%
SPAIN			1				1		1	3	0%	1%
SWITZERLAND	2			1						3	0%	1%
NORWAY	1						1	2		4	0%	2%
FINLAND	3			1			1			5	0%	2%
SWEDEN		1	2	4		1	1			9	1%	3%
NETHERLANDS	1		3	1	2		3			10	1%	4%
GERMANY	4	2	1	1		2	1		1	12	1%	5%
FRANCE	6	3	4	3	2	3	3	4	2	30	3%	7%
UNITED KINGDOM	6	1	21	6	1	7	9	1	8	60	5%	12%
JAPAN	1	4	2	5	3	3	2		6	26	2%	15%
CANADA	21		20	2	1	5	9	21	5	84	7%	22%
UNITED STATES	115	73	209	90	97	132	56	83	67	922	78%	100%
Total	161	84	263	115	106	153	88	112	95	1177	100%	
	14%	7%	22%	10%	9%	13%	7%	10%	8%	100%		

Las distribuciones de rating segmentadas según el sector industrial mantienen similares patrones que a nivel agregado (ver gráfico izquierdo de la Figura 10 y datos en la Tabla A 11 del Anexo C. Sin embargo, en la segmentación por países esta distribución cambia (ver gráfico derecho de la Figura 10 y datos en la Tabla 26). En el caso de empresas de Japón, hay muchas más compañías con la máxima calificación crediticia que en otras categorías de rating. A medida que mejora el nivel de calidad crediticia, el número de compañías clasificadas también aumenta. En cambio, las distribuciones relativas de compañías europeas y canadienses son muy similares entre ellas, concentrando el mayor volumen de los datos en los ratings A y BBB. Por último, los ratings de las compañías estadounidenses se distribuyen más simétricamente (ver Figura 10. Los histogramas de la izquierda están expresados en volúmenes totales, mientras que los de la derecha son frecuencias relativas).

Figura 10. Distribución de datos de rating por sector industrial (izquierda) y por país (derecha)



Las variables hasta aquí descritas se refieren a los ratings que se tienen en la muestra. A pesar de que el número de rating corporativos emitidos podría ser mayor, la muestra descrita es la que se ha logrado

luego del complejo proceso de vínculo con los datos que provee Datastream en su base de datos Worldscope (con información financiera de las compañías). Esto se debe a que no existe un identificador único que vincule los datos de aquel con S&P. Para vincular a las empresas que hay en ambas bases de datos, y relacionado con el proyecto de investigación MERITO, se construyó un conjunto de procedimientos que permitieron encontrar estas 1177 empresas comunes. Un resumen de dicho proceso se encuentra en el Anexo C. Para este grupo de empresas se tiene un conjunto de 32 variables cuantitativas que se refieren a la actividad de la compañía, su tamaño, su estructura de financiamiento, su liquidez, su rentabilidad y la volatilidad bursátil de sus acciones emitidas (ver Tabla 28). Las variables de actividad son expresadas en miles de dólares de EUA, la variable de volatilidad es un indicador porcentual respecto de la rentabilidad accionaria, mientras que todas las restantes son ratios o cocientes entre dos o más partidas contables. La elección de estas variables se realizó sobre la base de las variables utilizadas en trabajos de investigación y publicaciones en artículos pasados, que son revisados y presentados en el capítulo 2. Sobre todas variables a continuación se exponen los resultados del análisis exploratorio de la muestra.

Tabla 28. Variables financieras de la muestra que caracteriza a las compañías

Nombre de la variable	Tipo de variable	Nombre de la variable	Tipo de variable
ventas	(Indicador de Tamaño)	cobertura sobre la deuda	(Ratio de Financiamiento)
valor en bolsa	(Indicador de Tamaño)	proporción de deuda de largo plazo	(Ratio de Financiamiento)
rotación operacional	(Ratio de Actividad)	financiación de infraestructura	(Ratio de Financiamiento)
flujo de efectivo	(Ratio de Actividad)	proporción agregada	(Ratio de Financiamiento)
variación de ventas	(Ratio de Actividad)	dividendos entregados	(Ratio de Financiamiento)
cobertura de capital de trabajo	(Ratio de Liquidez)	valor de mercado de la empresa v/s	(Ratio de Financiamiento)
financiamiento de largo plazo	(Ratio de Liquidez)	valor contable de la deuda	(Ratio de Financiamiento)
proporción de inversiones de corto plazo	(Ratio de Liquidez)	porción fuentes externas	(Ratio de Financiamiento)
porción de deuda corriente sobre los activos	(Ratio de Liquidez)	cobertura de intereses	(Ratio de Rentabilidad)
necesidad de efectivo	(Ratio de Liquidez)	rentabilidad sobre inversión	(Ratio de Rentabilidad)
proporción de inversiones	(Ratio de Liquidez)	rentabilidad comercial	(Ratio de Rentabilidad)
necesidad de efectivo de mediano plazo	(Ratio de Liquidez)	rentabilidad sobre infraestructura	(Ratio de Rentabilidad)
capital de trabajo	(Ratio de Liquidez)	rentabilidad sobre inversión	(Ratio de Rentabilidad)
necesidad de efectivo de corto plazo	(Ratio de Liquidez)	rentabilidad sobre patrimonio	(Ratio de Rentabilidad)
nivel de stocks	(Ratio de Liquidez)	capacidad de autofinanciamiento	(Ratio de Rentabilidad)
proporción de inversiones corrientes	(Ratio de Liquidez)	Indicador de volatilidad bursátil	(Indicador de Volatilidad)
proporción de deuda corriente	(Ratio de Liquidez)		

4.1 Análisis descriptivo de las variables cuantitativas

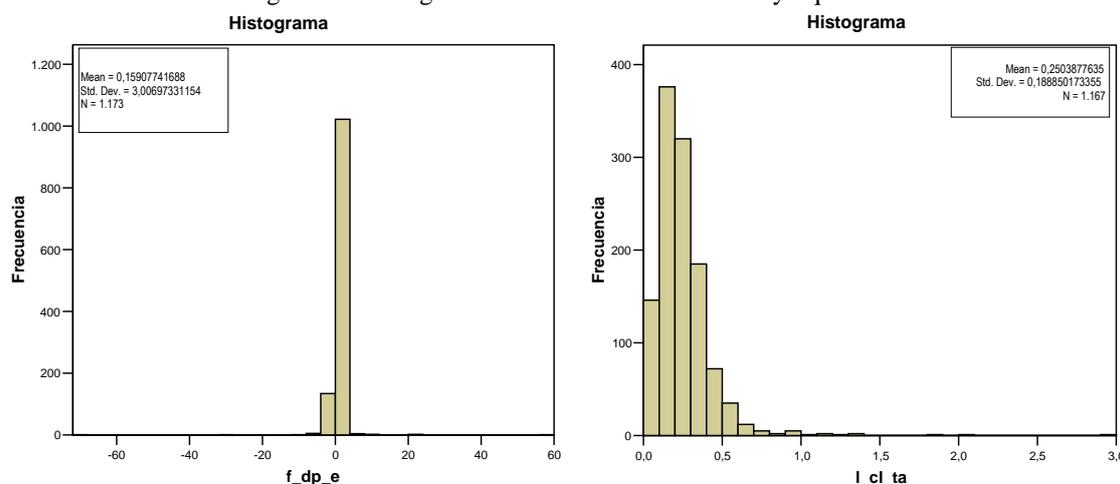
Del análisis de los estadísticos de los cuatro momentos de las 32 variables que se exponen en la Tabla 29, se puede observar que en 29 de ellas su media oscila entre 4 y -6, mientras que sus desviaciones estándares lo hacen entre 0,002 y 188,9. Las tres restantes variables tienen una magnitud muy diferentes: las variables de tamaño, porque están medidas en unidades monetarias, y la de volatilidad, porque es una medida porcentual. Los coeficientes de asimetría y de curtosis de las 32 variables tuvieron un amplio rango de valores. Los de simetría oscilan entre -33 y 33, mientras que los de curtosis lo hicieron entre -0,3 y 1154. Las evaluaciones realizadas sobre las variables de la muestra indican (i) la presencia de valores extremos de gran magnitud (mínimos y máximos) y (ii) la forma de las distribuciones no son normales.

Tabla 29. Estadísticos de los cuatro momentos para las variables de la muestra

Variable	nombre	Media	Desv. Típica	Asimetría	Curtosis
ventas	t_vtas	6.330.110	15.344.957	7,72	85,22
valor en bolsa	t_vm	6.592.571	20.090.031	7,56	72,61
rotación operacional	a_s-ta	0,956	0,693	1,88	5,33
flujo de efectivo	a_cf-s	-0,192	9,924	-33,40	1132,25
variación de ventas	a_vvtas	0,007	0,259	1,61	14,25
cobertura sobre la deuda	f_cf-td	0,142	0,247	16,25	436,77
proporción de deuda de largo plazo	f_ltd-ce	2,340	25,400	18,48	395,21
financiación de infraestructura	f_fa-ce	2,694	29,231	25,84	754,86
proporción agregada	f_td-ta	0,695	0,287	2,90	18,46
dividendos entregados	f_dp-e	0,159	3,007	-4,36	357,37
valor de mercado de la empresa v/s valor contable de la deuda	f_mvce-fl	0,001	0,002	9,19	160,30
porción fuentes externas	f_td-ce	4,045	39,232	20,51	515,40
cobertura de capital de trabajo	l_s-wc	-6,198	188,885	-11,68	237,61
financiamiento de largo plazo	l_wc-ltd	2,739	102,416	6,61	452,99
proporción de inversiones de corto plazo	l_wc-ta	0,101	0,229	-2,15	23,11
porción de deuda corriente sobre los activos	l_cl-ta	0,250	0,189	5,04	51,43
necesidad de efectivo	l_quick	1,199	2,539	15,08	283,72
proporción de inversiones	l_cas-ta	0,250	0,163	1,20	1,57
necesidad de efectivo de mediano plazo	l_cas-cl	1,346	2,580	14,89	278,80
capital de trabajo	l_ca-cl	1,798	2,634	13,58	244,97
necesidad de efectivo de corto plazo	l_c-cl	0,625	2,505	15,70	298,53
nivel de stocks	l_i-tca	0,256	0,213	0,73	-0,09
proporción de inversiones corrientes	l_ca-ta	0,352	0,206	0,55	-0,33
proporción de deuda corriente	l_cl-tl	0,371	0,201	0,76	0,43
cobertura de intereses	g_ebit-i	0,378	28,070	-25,15	769,95
rentabilidad sobre inversión	g_nia-ta	0,045	0,279	13,05	336,22
rentabilidad comercial	g_ebit-s	-0,598	17,112	-33,61	1141,52
rentabilidad sobre infraestructura	g_ronfa	0,050	2,787	7,99	235,27
rentabilidad sobre inversión	g_ebit-a	-0,005	0,276	11,78	308,68
rentabilidad sobre patrimonio	g_roe	1,405	52,229	33,81	1154,14
capacidad de autofinanciamiento	g_re-ta	-0,046	1,139	-11,44	172,35
Indicador de volatilidad bursátil	v_vol250	58,125	43,347	4,14	29,84

Los estadísticos de tercer y cuarto momento también tienen una gran dispersión y evidencian asimetrías y curtosis muy altas. Como se puede observar en la Tabla 29, en el 72% de las curtosis es mayor a 50, es decir, su distribución es muy leptocúrtica. Esto significa que las distribuciones de los datos distan mucho de parecerse a una normal. Un ejemplo de la elevada curtosis se puede observar en la imagen de la izquierda de la Figura 11. Sólo 3 de las 32 variables son mesocúrticas (como una distribución normal): *nivel de stocks*, *proporción de inversiones corrientes* y *proporción de deuda*.

Figura 11. Histogramas de ratios de financiación y liquidez



Otra característica de los datos de esta muestra es que la mayoría de las variables (25 de las 32 variables) tiene asimetría positiva, es decir, sus colas son más prolongadas hacia la derecha. Además,

el 34% de las 32 variables tiene el estimador de asimetría mayor que 10 y el 16% tiene una asimetría menor que -10. Estos coeficientes indican que las distribuciones de las variables son excesivamente asimétricas, dejando muy pocas posibilidades a que se pueda suponer una distribución normal de los datos. Un ejemplo de asimetría positiva extrema se puede advertir en el histograma de la variable de liquidez *proporción de deuda corriente* (l_cl_ta), de la derecha de la Figura 11.

Siguiendo a Hair et al. (1999), además de examinar la curtosis y la asimetría de las variables para evaluar si los datos se asemejan o no a la distribución normal, se pueden revisar sus histogramas (desde la Figura A 2 a la Figura A 7, del Anexo C) y realizar el test Kolgomorov-Smirnov corregido (ver Tabla A 15 del Anexo C). De la evaluación gráfica sólo las variables de liquidez l_ca_ta y l_cl_tl tienen una leve semejanza a la forma de una distribución normal, mientras que el contraste estadístico rechaza, con 1% de error, la posibilidad de que cada una de las distribuciones sea normal.

Por otra parte, entre las variables explicativas del rating hay correlaciones de muy diverso tipo y magnitud. Muchas de ellas están cercanas a cero (revisar la Tabla A 14 del Anexo C). Sin embargo, las *correlaciones intra-área*²³ suelen ser positivas de mayor magnitud que la correlación. Para el cálculo de las correlaciones se ha utilizado el método de Tau-b de Kendall, ya que permite mejores estimadores cuando las distribuciones de los datos no son normales (Visauta, 1998). De todas las correlaciones se pueden rescatar las siguientes generalizaciones:

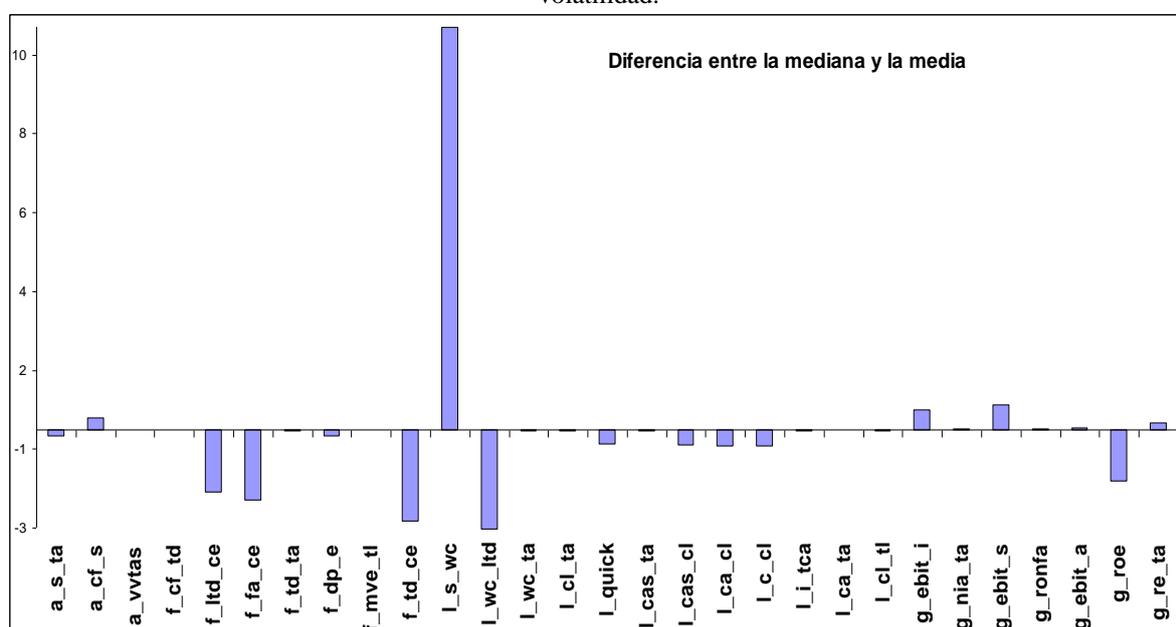
- las correlaciones intra-área de las variables de rentabilidad son las de mayor intensidad. No obstante, la correlación entre las variables de rentabilidad y las otras variables es casi nula, especialmente con las de liquidez.
- La correlación entre las variables de financiamiento y liquidez existe una pequeña, pero negativa correlación. Esto también ocurre entre la variable de volatilidad y las restantes variables, a excepción de las de liquidez, donde sólo una variable tiene una muy baja correlación negativa con la de volatilidad.

Otro hecho destacable de los datos, es que 12 de las 32 variables, que están en la Tabla 29, tienen muchos datos que son valores extremos; tanto así que la media y la mediana se distancian bastante entre ellas (la mediana de las variables se encuentran en la Tabla A 13 del Anexo C). Es conocido que el efecto de estos valores extremos en técnicas estadísticas, como por ejemplo AD y regresión logística, es muy nocivo (Choi, 2009). En la Figura 12 se grafican las diferencias entre la mediana y la media para dejar en evidencia la magnitud de dichos valores extremos en 29 de las variables de la muestra (en esta figura se han descartado las de tamaño y la de volatilidad debido a que tienen distintas escalas). La mayor distancia entre ambos estadísticos se produce en la variable de liquidez

²³ En esta tesis supondremos que una *correlación intra-área* es aquella que hay entre una variable y otra de su misma agrupación financiera: tamaño, actividad, financiamiento, liquidez, rentabilidad y volatilidad.

cobertura de capital de trabajo (l_s_wc). Lo usual que ocurre en muchas empresas es que su media es mayor que uno, ya que la ratio se calcula dividiendo las ventas por el capital de trabajo (ambas cifras suelen positivas y las ventas suelen ser mayores en volumen). Sin embargo, en esta oportunidad esta gran diferencia se debe a que un grupo reducido de empresas no tiene esta caracterización. Estas empresas pertenecen a los sectores *General Industries*, *Cyclical Consumer Goods* y *Non-Cyclical Services* (ver los gráficos de barra en la Figura A 16 del Anexo C). El efecto de estos valores extremos se confirma con el diagrama de caja de esta variable en la Figura A 12 y con los valores que toman el rango y la amplitud intercuartil en esta variable en la Tabla A 13, todas ellas en el Anexo C. Las otras variables que tienen valores muy extremos son *f_wc_ltd*, *f_td_ce*, *f_fa_ce* y *f_ltd_ce*.

Figura 12. Distancia entre la mediana y la media de las variables cuantitativas excluyendo a las de tamaño y volatilidad.



Al revisar visualmente las restantes variables con los diagramas de caja, casi todas las variables evidencian valores extremos, y sólo cuatro variables presentaron valores atípicos, pero no valores extremos²⁴ (ver desde la Figura A 8 hasta la Figura A 13 en el Anexo C). Todas las variables que no contenían casos extremos fueron de liquidez: *proporción de deuda corriente (l_cl_ta)*, *nivel de stocks (l_i_tca)*, *proporción de inversiones corrientes (l_ca_ta)* y *proporción de deuda corriente (l_cas_ta)*. Sus diagramas de caja se encuentran en la Figura A 12, del Anexo C, donde los valores aislados se presentan con una circunferencia y los extremos con un asterisco. Además, más de la mitad de las variables tienen casos atípicos o casos extremos que representan entre un 10% a 20% de los casos (ver Tabla A 38, del Anexo C). De éstos, los casos atípicos y extremos por debajo de la caja hay un mayor

²⁴ En esta tesis se entiende como caso atípico a aquella observación que está entre 1,5 y 3 longitudes de caja desde el borde inferior o superior del diagrama de caja, y por caso extremo a aquella que está a más de 3 longitudes de caja.

número en las variables de rentabilidad, mientras que los valores atípicos y extremos superiores (por arriba de la caja) están más dispersos.

Por otra parte, para evaluar multivariadamente el efecto de los valores extremos se puede utilizar el test D^2 de la distancia de Mahalanobis y el test de la distancia de Cook. Siguiendo el criterio propuesto en Hair et al. (1999) al evaluar test D^2 de Mahalanobis, se debe rechazar la hipótesis de la existencia de casos aislados significativamente influyentes (al 1%), mientras que bajo el criterio de la distancia de Cook sólo el 5% de los datos (58 compañías) influyen globalmente (ver Tabla A 16 del Anexo C). Esto indicaría que aunque a nivel univariante la presencia de valores extremos sea identificable, a nivel multivariante y global de los datos, no existen evidencias de influencias excesivas causadas por los valores extremos como para invalidar la muestra.

Hasta aquí se ha expuesto un análisis de los estadísticos de las variables de la muestra y en la sección anterior se expuso la relación que estas variables tienen con el rating. Adicionalmente, al realizar una exploración de los estadísticos de los cuatro momentos una vez segmentados los datos por rating la presencia de valores extremos disminuye de una manera significativa. Con dicha segmentación las diferencias entre la media y la mediana en la mayoría de las variables se reducen drásticamente (ver la Tabla A 18 y la Tabla A 19 en el Anexo C). Sin agrupar los datos, hay 3548 casos con valores extremos y al agrupar los datos por rating, se redujo a 2975 casos; es decir, un 16% de menos valores extremos (ver Tabla A 20 del Anexo C). Estas evidencias indican que si existen diferencias entre las empresas cuando éstas son segmentas por rating, lo que es relevante para la tarea de réplica, ya que esto permite aplicar una técnica clasificatoria. Incluso, siguiendo a Hair et al. (1999), esta es una evaluación que debe realizarse cuando se utiliza AD.

A pesar de que el número e importancia de los valores extremos es mucho menor cuando se segmentan los datos por clase de rating, aun algunos de éstos prevalecen en algunas variables. Los casos más significativos están en *l_s-wc*, *t_vtas*, *t_vm*, *l_wc-ltd*, *g_ebit-i* y *v_vol250*, en orden de importancia del valor extremo (ver Tabla A 19 en el Anexo C). Una posible explicación de la existencia de los datos extremos, puede ser porque en algunas compañías la pertenencia a un sector industrial determina su propia estructura de financiación y de gestión, y por lo tanto, a sus ratios. Esto es coherente con investigaciones recogidas de la literatura financiera, que incluyen alguna variable relacionada con el sector industrial de la compañía que permita una más acertada predicción del riesgo crediticio (Shin y Han, 2001). Además, algunos autores corroboran la existencia de diferencias entre tasas de fallido de diferentes sectores industriales cuando se producen cambios en el estado de la economía (Couderc y Renault, 2004).

4.2 Relaciones entre las variables cuantitativas y el rating

A continuación se expone el resultado de la exploración visual entre las variables cuantitativas de las compañías y el rating debido a la importancia que diversos autores (Hair et al., 1999) dan a la indagación de la existencia de dichas relaciones antes de usar técnicas que permitan predecir. De este análisis, en 20 de las 32 variables existen indicios de algún tipo de relación con el rating. En cambio, en las 12 restantes variables esta relación es confusa. De estas 20 variables cuya identificación es clara, 9 tienen una relación directa, 3 inversa, 7 sinusoidal y 1 comienza siendo inversa y termina siendo directa (ver Tabla 30). Cabe hacer hincapié en la importancia de esta relación: en la medida que estas relaciones es más fuerte y limpia, mayor será la capacidad de replicar el rating por alguna técnica predictiva. Aun más, si las relaciones son lineales, las técnicas estadísticas que asumen este tipo de relación podrán capturar esta información con mayor facilidad, como ocurre con AD (Hair et al., 1999). Por al contrario, si las relaciones son poco claras, imprecisas y espurias es menos probable que se pueda replicar el rating.

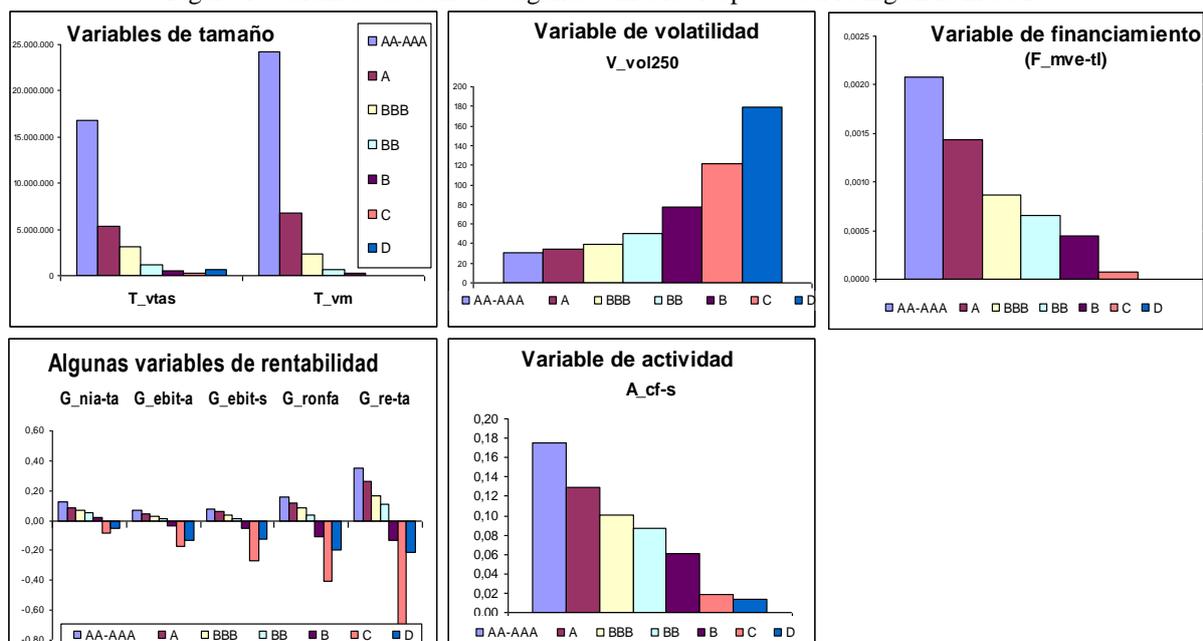
Los distintos tipos de relaciones observadas entre las variables y el rating se exponen en la Tabla 30. Junto al nombre de la variable se exhibe la relación observada en el análisis exploratorio de la muestra y la relación esperada desde el punto de vista teórico recogido de la revisión de la literatura financiera del capítulo 2 (ver Tabla 16). Como se puede observar, en muchas de las oportunidades, la relación teórica esperada coincide con la relación observada desde los datos de la muestra.

Tabla 30. Tipo de relaciones visuales en la muestra entre las variables del rating

Nombre	Concepto	Relación observada	Relación esperada	Nombre	Concepto	Relación observada	Relación esperada
t_vtas	tamaño	directa	directa	l_quick	liquidez	confusa	directa
t_vm	tamaño	directa	directa	l_cas-ta	liquidez	confusa	directa
a_s-ta	actividad	directa	directa	l_cas-cl	liquidez	confusa	directa
a_cf-s	actividad	directa	directa	l_ca-cl	liquidez	confusa	directa
a_vtas	actividad	confusa	directa	l_c-cl	liquidez	confusa	directa
f_cf-td	financiación	directa	directa	l_i-tca	liquidez	inversa → directa	inversa
f_ltd-ce	financiación	inversa	inversa	l_ca-ta	liquidez	confusa	directa
f_fa-ce	financiación	directa	directa	l_cl-tl	liquidez	directa	directa
f_td-ta	financiación	inversa	inversa	g_ebit-i	rentabilidad	senoidal	directa
f_dp-e	financiación	directa	directa	g_nia-ta	rentabilidad	senoidal	directa
f_mve-tl	financiación	directa	directa	g_ebit-s	rentabilidad	senoidal	directa
f_td-ce	financiación	confusa	inversa	g_ronfa	rentabilidad	senoidal	directa
l_s-wc	liquidez	confusa	inversa	g_ebit-a	rentabilidad	senoidal	directa
l_wc-ltd	liquidez	confusa	directa	g_roe	rentabilidad	senoidal	directa
l_wc-ta	liquidez	confusa	directa	g_re-ta	rentabilidad	senoidal	directa
l_cl-ta	liquidez	confusa	inversa	v_vol250	volatilidad	inversa	inversa

En la Figura 13 están las relaciones más fáciles de comprender en este análisis visual: las variables de tamaño, la variable de volatilidad, las variables de rentabilidad, la variable de financiamiento *valor mercado v/s valor contable* y la variable de actividad *flujo de efectivo*. En la Tabla A 17 del Anexo C está la mediana de cada variable segmentada por clases de rating, y la Figura A 14, con los gráficos de barra de todas las variables agrupadas por rating.

Figura 13. Gráficos de barra de algunas variables respecto del rating en la muestra



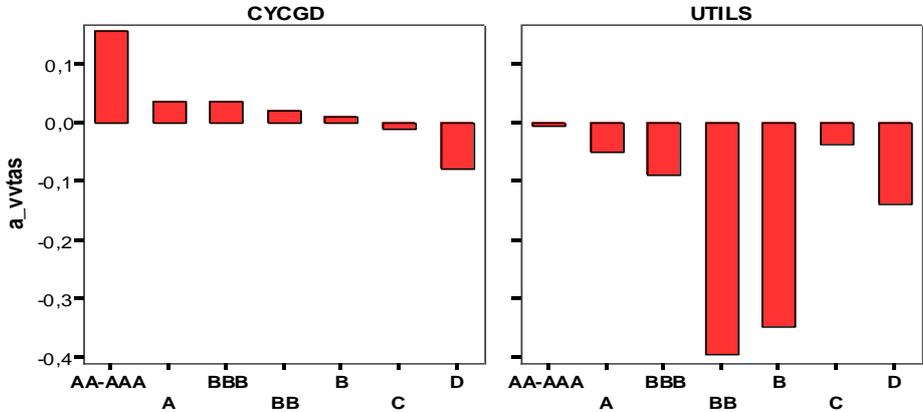
En esta Figura 13 las gráficas de barra muestran los valores de las medianas por cada rating (de nivel 2). Cuando la relación es directa se observa que los valores de los ratios son mayores cuando el rating es de mayor calidad crediticia. En el ejemplo, la variable de financiación *valor mercado de la empresa sobre valor contable de la deuda* tiene este comportamiento. Una interpretación financiera de esta relación supondría que cuando el mercado castiga al precio de la acción, pagando menos por ella, el castigo está relacionado directamente con la calidad crediticia evaluada por S&P al emitir el rating.

Las relaciones inversas observadas desde la muestra y expuestas en la Tabla 30 indican que la variable es menor cuando la calidad crediticia medida por S&P es mayor. La variable de volatilidad tiene este comportamiento en la Figura 13. Esto indicaría que los precios de las acciones con rating bajo tienen mayores oscilaciones que aquellas que tienen alto rating. Por otra parte, las relaciones sinusoides de la muestra indican que en la medida que las compañías tienen mejor rating, la ratio es mayor (como una relación directa), hasta un punto de inflexión donde la relación ya no es directa, sino inversa. En la muestra, esta inflexión ocurre en las compañías con rating C. Por ejemplo, se observa una relación sinusoidal en la variable *rentabilidad sobre infraestructura (g_ronfa en la Figura 13)*, donde las compañías con rating AAA o AA obtienen la más alta ratio; en la medida que desciende la calificación de S&P, la ratio de las compañías también lo hace hasta el rating C, donde toma el menor valor negativo y se produce la inflexión, cambia la relación de directa a inversa.

Más del 60% de las variables exhibe alguna relación con rating. Las variables que no ofrecen una relación fácilmente distinguible están afectadas por otros elementos o bien, existen características de las compañías que imposibilitan esta fácil interpretación, como por ejemplo el sector industrial. Esto se debe a que las estructuras y decisiones de financiamiento e inversión de las compañías suelen ser

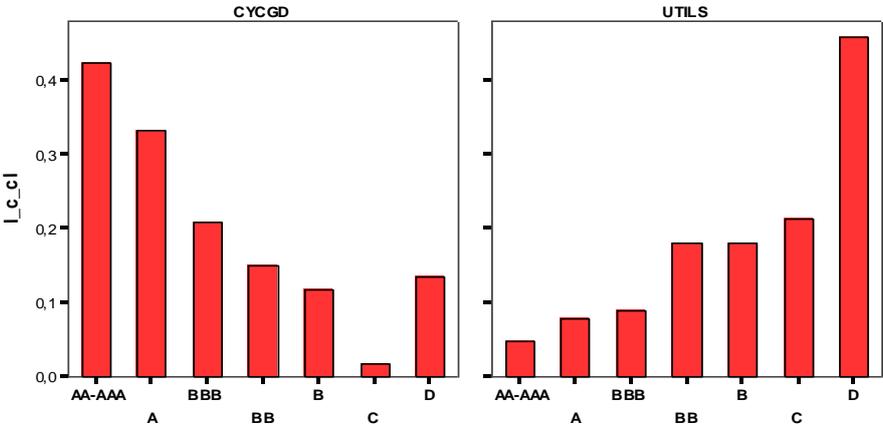
muy diferentes según la actividad comercial que desarrollen. Por ejemplo, una cadena de supermercados tendrá un nivel de inventarios más significativo que una compañía desarrolladora de software, y a su vez, ésta puede tener niveles de capital de trabajo distintos a una compañía de transporte público. Estas disimilitudes en las actividades empresariales generan diferenciaciones entre las ratios. Por ello, al segmentar los datos por cada sector industrial no hubo claros indicios de que esta segmentación aclara todas las relaciones *confusas*. Todas las gráficas de estas variables analizadas se encuentran en el Anexo C desde la Figura A 15 hasta la Figura A 20. En cambio en unos pocos casos se encontraron relaciones muy especiales como es el caso de la variable *variación de ventas* (*a_vvtas*) entre las compañías del sector *Cyclical Consumer Goods* y las del sector *Utilities* (ver Figura 14). Se puede observar que el primero de estos segmentos industriales la relación es directa, pero en el sector industrial de *Utilities* la relación es senusoide, con punto de inflexión en el rating BB.

Figura 14. Medianas de la variable *a_vvtas* de 2 sectores industriales agrupadas por rating



Otra situación extraña ocurre en la variable de liquidez *l_c_cl*, ya que las relaciones son opuestas cuando se compran los resultados entre los sectores *Cyclical Consumer Goods* (CYCGD) y *Utilities* (UTILS). Como se ve en la Figura 15, en el primer caso la relación es directa y en el otro es inversa.

Figura 15. Medianas de *l_c_cl* de compañías de CYCGD y UTILS agrupadas por rating



Estas evidencias acerca de las diferencias que hay en algunas variables, respecto de la industria y del país, justifican el análisis de los estadísticos de los 4 momentos y de correlaciones de los datos segmentados de acuerdo a estos dos criterios. Sus resultados se exponen a continuación.

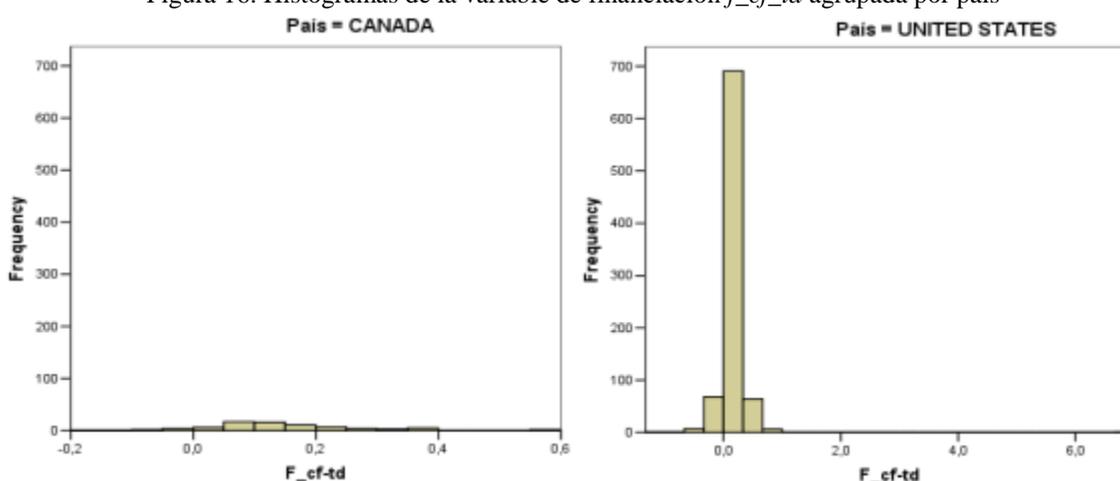
4.3 Análisis de las variables agrupadas

4.3.1 Agrupación por países

En adelante se exhiben los resultados del análisis de las 32 variables agrupadas por países. No obstante, los datos de las compañías europeas se unieron en un mismo bloque, debido a la proximidad de su ciclo económico y demográfico²⁵, al mercado monetario único que hay en la UE y a la escasez de datos de empresas en algunos países europeos.

En general, los estadísticos de los cuatro momentos presentaron una gran dispersión (ver en la Tabla A 21 del Anexo C). La mayoría de los estadísticos son similares a aquellos obtenidos de los datos sin segmentación, a excepción de las variables de tamaño (donde la media y la mediana tienen grandes diferencias con los datos sin agrupar) y las variables de liquidez *cobertura de capital* (l_s_wc) y de financiación *financiamiento de largo plazo* (l_wc_ltd), que evidencian excesivos valores extremos. Sin embargo, la semejanza entre estos estadísticos no significa que las distribuciones de datos agrupados por país sean similares entre sí. La Figura 16 es prueba de ello. En esta figura se pueden comparar las distribuciones de una variable de financiación f_cf_td de compañías de Canadá y EUA. Ambas difieren significativamente aunque sus estadísticos de media, mediana y desviación estándar son muy cercanos. En el ejemplo de esta variable, la mayor discrepancia está en la curtosis, ya que para los datos de EUA, esta variable de financiación tiene una elevada leptocurtosis (384,5), mientras que los datos de las compañías canadienses tienen una curtosis poco mayor que 1 (Tabla A 21 del Anexo C).

Figura 16. Histogramas de la variable de financiación f_cf_td agrupada por país



Generalizando, un rasgo característico de los datos segmentados por país es la elevada curtosis. El 38% de las 128 estimaciones de curtosis (32 para cada país o bloque de países) es mayor que 20. Del

²⁵ Respecto de las características similares que tienen las economías de europeas recomendamos las lecturas de Freimann (1998), Prskawetz, Fent et al. (2007), Haiss y Sümegei (2008), Gonçalves, Rodrigues y Soares (2008), entre otros.

examen de la asimetría de las variables se puede observar que éstas suelen ser bastante irregulares, aunque la mayor parte de ellas son mayores que 2 (ver en la Tabla A 21 del Anexo C). Los variables con mayor curtosis son *a_cf_s*, *g_roe* y *g_ebit_s*, para los grupos de compañías estadounidenses donde los estadísticos de curtosis son mayores que 800.

Por otro lado, de la matriz de las correlaciones agrupadas por país se puede observar que éstas son similares a las observadas en la matriz de correlación sin agrupar, pero ciertos grupos de correlaciones tienen mayor intensidad. En general, el valor absoluto de cada correlación intra-área es mayor que la correlación calculada con todos los datos de la muestra sin segmentar (comparar resultados de la Tabla A 14 con los expuestos entre la Tabla A 25 y Tabla A 28, del Anexo C).

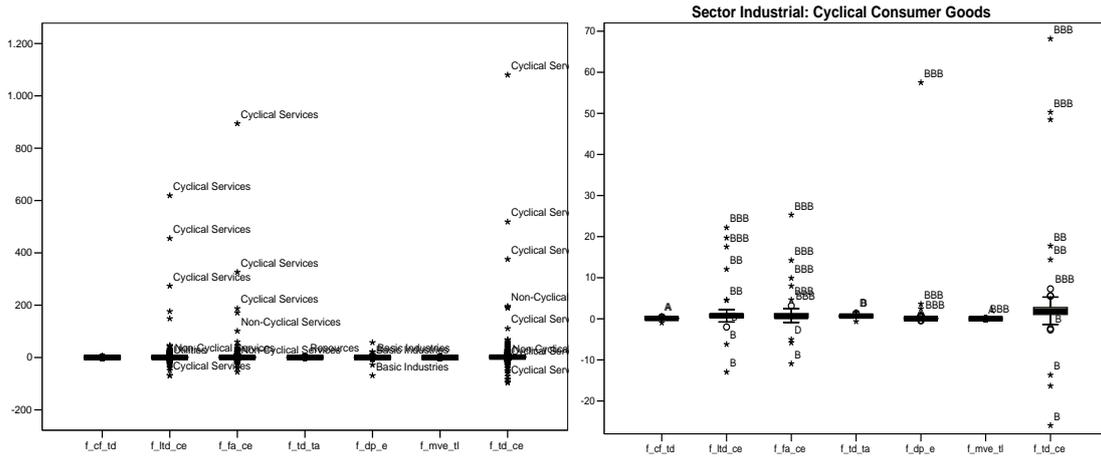
Otra particularidad es que las matrices de correlación de las compañías de EUA (Tabla A 27) y Canadá (Tabla A 28) tienen grandes similitudes. Entre éstas y las correlaciones de compañías europeas también existen semejanzas, aunque se percibe que las correlaciones de empresas europeas son más intensas, es decir, el valor absoluto de las correlaciones es levemente superior que las americanas, sobre todo en las variables de liquidez. Por otra parte, las compañías japonesas tienen correlaciones mucho más elevadas que las matrices de los otros países, tanto positiva como negativamente. Otra diferencia entre las correlaciones de las compañías japonesas, es que las correlaciones de las variables de liquidez niponas son más intensas, incluso algunas correlaciones llegan a cambiar el signo. Los mayores cambios se dan en las correlaciones entre las variables de liquidez y la variable de financiación *f_ltd_ce* (los mayores cambios llegan al 60%).

En resumen, no existen patrones fácilmente identificables para señalar que cada país constituye un grupo distinguible. La única prueba que hace diferente a los distintos grupos de datos es la disimilitud entre las correlaciones de las compañías japonesas con las matrices de correlación de los otros países. Sin embargo, la separación de las compañías japonesas del resto de los datos resulta inapropiada, ya que la muestra nipona sólo contaría con 26 compañías y con muy poca dispersión.

4.3.2 Agrupación por sector industrial

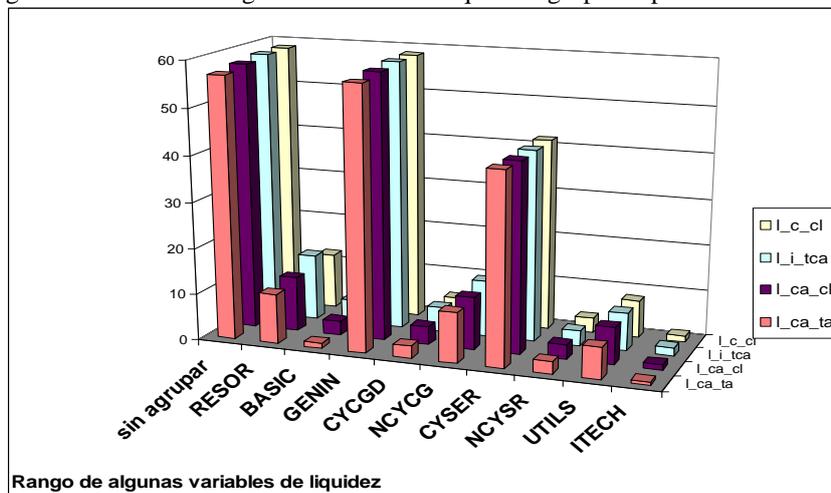
La agrupación de datos de la muestra por el sector industrial para dividirla en subconjuntos muestrales se ha realizado según el nivel 3 de la clasificación industrial basado en el Financial Times Stocks Exchange, que proporciona Thomson Financial (ver Tabla A 5 del Anexo C). Uno de los primeros fenómenos que se pudieron observar de esta agrupación es que los valores extremos muy alejados se redujeron significativamente.

Figura 17. Diagramas de caja de variables de financiación



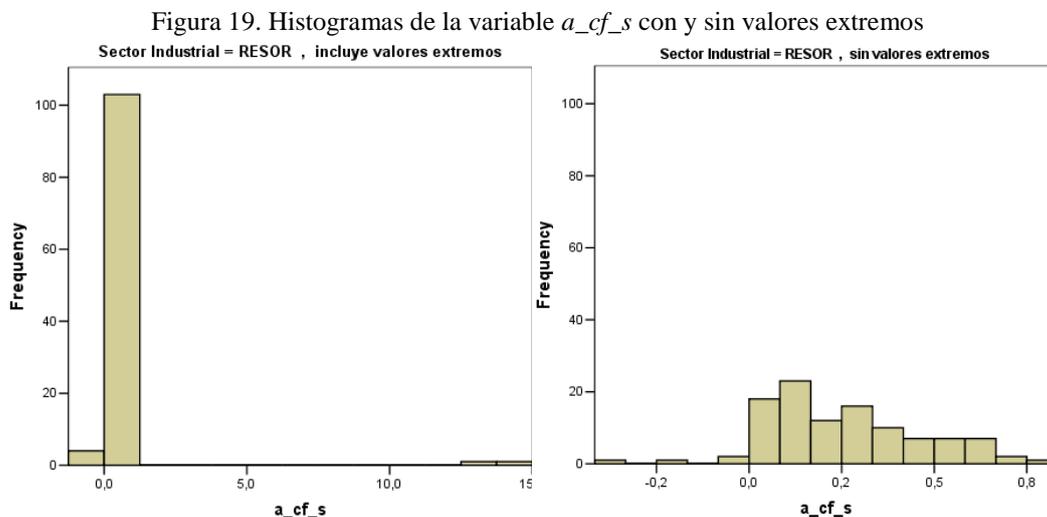
En la Figura 17 se puede observar como disminuyeron drásticamente los valores extremos al segmentar los datos por industria. Vea que, en los diagramas de caja, sus escalas de medida son muy distintas. El diagrama de la izquierda contiene las cajas de las variables de financiación de todos los datos sin segmentar, y se necesita una escala numérica que va desde el -200 a 1200 y con muchos valores extremos que son del sector *Cyclical Services* (CYSER). Cada punto que está fuera del diagrama de caja y está marcado con una estrella es un valor extremo (con su sector industrial). Sin embargo, el diagrama de la derecha, con las mismas variables y sólo con datos del sector *Cyclical Consumer Goods* (CYCGD), presenta una escala mucho más reducida (de -20 a 70). Se puede observar que también hay valores extremos, pero éstos son de mucha menor magnitud. Esta caracterización se repite en la mayoría de las variables con divisiones industriales. En algunos casos la agrupación por sector industrial permite que los subconjuntos tengan menos valores extremos, como el caso de la variable de liquidez *financiamiento de largo plazo* (l_{wc_ltd}); pero en otras variables el efecto de la disminución de los valores extremos debido a la agrupación es mínimo, como ocurre con la variable de tamaño *valor en bolsa* (t_{vm}).

Figura 18. Valor del rango de variables de liquidez agrupadas por sector industrial



En la Figura 18 están graficados los rangos (diferencia entre el valor mínimo y máximo) de algunas variables de liquidez sin la agrupación y con los datos agrupados (los datos están en la Tabla A 23 del Anexo C). Las barras de la izquierda son los rangos de la variable sin agrupar y los restantes son los rangos una vez agrupados por sector industrial. La persistencia de dos sectores industriales con rangos elevados (GENIN y CYSER) indica que a pesar de la disminución de puntos extremadamente alejados de su media aun persisten. Las gráficas de barra de las restantes variables se encuentran en la Figura A 22 del Anexo C.

Al igual que en las agrupaciones por país y por rating, en la agrupación industrial las variables *cobertura de capital* y *cobertura de intereses* (*l_s_wc* y *g_ebit_i*, respectivamente) se ven afectadas por excesivos valores extremos. Dichos valores extremos cambian la percepción del observador. Por ejemplo, en la Figura 19 están los histogramas de la variable de actividad *a_cf_s* con y sin valores extremos (sólo del sector RESOR). El histograma de la izquierda ha incluido todos los datos de la variable y el de la derecha ha excluido dos compañías que contenían datos extremos. Dicha exclusión, hizo cambiar levemente la media (de 0,23 a 0,22) y la desviación estándar (de 1,85 a cambió de 0,21), mientras que la curtosis y la asimetría bajaron bruscamente, de 50 a 0,2 y de 7 a 0,3, respectivamente. Otra variable que cambia su curtosis cuando se agrupan los datos por industria es la *rentabilidad sobre el patrimonio* (*g_roe*), que medida globalmente tiene una curtosis igual a 1155 y que al segmentar en grupos industriales la máxima curtosis es 183 y las restantes bordean los 30 puntos.



Los estadísticos de asimetría también sufrieron cambios. Muchos de los estimadores disminuyeron su intensidad (positiva o negativamente), como ocurre con la variable *g_roe*, cuya asimetría sin agrupar es 34 y una vez agrupados los datos la asimetría oscila entre -12,8 y 9,4 (ver Tabla A 22 del Anexo C). Un fenómeno destacable es el que ocurre en el sector *Cyclical Services* (CYSER), donde en forma recurrente hay medias de mayor magnitud que el resto de los grupos. Esto es más notorio para las variables de liquidez, donde el sector *Non-Cyclical Consumer Goods* (NCYCG) también presenta

mayor medidas de centralidad, por lo que se deduce que las empresas de este sector necesitan más recursos líquidos que las otras compañías para desarrollar sus actividades.

Luego de analizar las matrices de correlaciones de las variables agrupadas por industria, es posible concluir que éstas tienen similar distribución de valores que la matriz sin agrupación (ver desde la Tabla A 29 a la Tabla A 37, del Anexo C). Sin embargo, el valor absoluto de las correlaciones intra-área suele ser de mayor magnitud (algunas llegaron a 0,92) cuando son agrupadas por industria.

Las disimilitudes entre las matrices de correlación por grupos industriales obedecen a cambios en la intensidad más que en el signo de los estadísticos. Las correlaciones de los sectores RESOR, BASIC, CYCGD, CYSER y GENIN son similares entre sí, con la distinción que se fortalecen las correlaciones intra-área y se debilitan las restantes correlaciones. Por otra parte, que las correlaciones intra-área de los sectores NCYCG y UTILS se debilitan levemente (sin que lleguen a cero) y las restantes correlaciones de dichos sectores (las que están fuera de la intra-área) se fortalecen levemente, sin pasar el umbral de los $\pm 0,3$, en la mayoría de los casos (verificables en las matrices de correlación de la Tabla A 29 hasta la Tabla A 37 del Anexo C)

Finalmente, segmentar las variables por sector industrial permite dispersar menos los datos, concentrándolos en grupos más homogéneos, proporcionando información más depurada. Luego de analizar las correlaciones y las características de los valores extremos por grupo de variables financieras (tamaño, actividad, financiación, liquidez, rentabilidad y volatilidad) para cada uno de los sectores industriales (ver la Tabla A 24 del Anexo C) se puede constatar que una posible segmentación de datos podría ser a través de la reagrupación de sectores industriales, los que estarían conformados por los siguientes sectores: a) RESOR, BASIC, CYCGD y GENIN, b) CYSER, c) NCYCG y UTILS, d) NCYSR e ITECH. Sin embargo, el principal problema para la réplica de rating estaría en el tamaño de los grupos, ya que habría algunos que tendrían muy pocos datos de rating y además, la muestra estaría muy desbalanceada. Por ejemplo, de la fusión de NCYSR e ITECH, el nuevo macro-sector sólo tendría el 16% de datos de la muestra; de los cuales sólo 4 empresas tienen rating AAA-AA (ver Tabla A 11 en el Anexo C). Esto es un grave problema para el proceso de entrenamiento/ajuste y causa problemas muy difíciles de resolver cuando se usan técnicas estadísticas como AD. Por lo tanto, para la réplica de rating con esta muestra la segmentación industrial no resulta aconsejable.

4.4 Evaluación de datos ausentes

Otra evaluación importante en una muestra como la construida en esta oportunidad es la evaluación a nivel global de los datos ausentes o missing values. En una primera inspección se han evaluado, junto con los casos de missing values, los datos que tuvieran valor cero y los poco comunes o extraños

(como por ejemplo cuando el pasivo es negativo), pero que no fueran valores extremos. Esto se ha realizado para evaluar si se cometieron errores de imputación en los datos. En total el número de missing values es de 302 y el total de valores igual a cero es de 688, y de ellos, las compañías que particularmente han llamado la atención son 11 empresas con doce o más datos vacíos, y 3 casos con nueve o más datos vacíos y valores igual a cero. De estos casos detectados e identificados la evaluación de la posible concentración por variables cualitativas (sector industrial, país, opinión de auditores y rating), indica que éstos siguen similares patrones de la distribución total de datos. Esto se puede observar en la Tabla 31 y en el Tabla A 40 del Anexo C. Una última observación es que de los 302 valores ausentes, sólo 92 se deben a que no existían los datos originales que generan la variable. Los restantes 210 casos no están disponibles en la muestra porque el valor calculado ha resultado ser ilógico matemáticamente, como por ejemplo cuando en un cociente el denominador es igual a cero.

Tabla 31. Distribución de los datos vacíos

Distribución por sector industrial									
C_indc3	1	2	3	5	12	13	15	Total	%
BASIC	8	1	1	1				11	12%
CYCGD	2	1			1		1	5	5%
CYSER	11	1	8		6	1		27	29%
GENIN	2	1	1			1		5	5%
ITECH	2	4	1					7	8%
NCYCG	5							5	5%
NCYSR	5		2					7	8%
RESOR	10		4	1	1			16	17%
UTILS	5	1	3					9	10%
Total	50	9	20	2	8	2	1	92	100%

C_indc3	Nº datos totales y su %	
BASIC	161	14%
CYCGD	84	7%
CYSER	263	22%
GENIN	115	10%
ITECH	106	9%
NCYCG	153	13%
NCYSR	88	7%
RESOR	112	10%
UTILS	95	8%
Total	1177	100%

Al analizar los datos ausentes por cada variable, f_{dp_e} y l_{i_tca} muestran una alta concentración de valores igual a cero (ver en la Tabla 32 los 519 y 116 casos, respectivamente), y las variables l_{wc_ltd} , l_{cas_ta} , l_{cas_cl} , l_{i_tca} , g_{re_ta} y v_{vol250} tienen los mayores números de casos de datos ausentes. Las ratios que tienen una alta concentración de valores igual a cero se deben a que las empresas no pagan dividendos en efectivo y a que las compañías mantienen escasos o nulos niveles de inventarios.

Tabla 32. Distribución por variable de missing values y de valores nulos

	N	Missing Values		$x_i = 0$	
		n	%	n	%
t_vtas	1177	0	0,00%	4	0,34%
t_vm	1163	14	1,19%	1	0,09%
a_s_ta	1177	0	0,00%	4	0,34%
a_cf_s	1173	4	0,34%	0	0,00%
a_vtas	1173	4	0,34%	0	0,00%
a_cf_td	1177	0	0,00%	0	0,00%
f_ltd_ce	1175	2	0,17%	14	1,19%
f_fa_ce	1172	5	0,42%	3	0,26%
f_td_ta	1177	0	0,00%	0	0,00%
f_dp_e	1173	4	0,34%	519	44,25%
f_mv_e_tl	1167	10	0,85%	0	0,00%
f_td_ce	1175	2	0,17%	0	0,00%
l_s_wc	1167	10	0,85%	4	0,34%
l_wc_ltd	1153	24	2,04%	0	0,00%
l_wc_ta	1167	10	0,85%	0	0,00%
l_cl_ta	1167	10	0,85%	0	0,00%
l_quick	1161	16	1,36%	0	0,00%
l_cas_ta	1154	23	1,95%	0	0,00%
l_cas_cl	1154	23	1,95%	0	0,00%
l_ca_cl	1167	10	0,85%	0	0,00%
l_c_cl	1166	11	0,93%	19	1,63%
l_i_tca	1154	23	1,95%	116	10,05%
l_ca_ta	1167	10	0,85%	0	0,00%
l_cl_tl	1167	10	0,85%	0	0,00%
g_ebit_i	1168	9	0,76%	0	0,00%
g_nia_ta	1173	4	0,34%	0	0,00%
g_ebit_s	1171	6	0,51%	0	0,00%
g_ronfa	1169	8	0,68%	0	0,00%
g_ebit_a	1175	2	0,17%	0	0,00%
g_roe	1174	3	0,25%	0	0,00%
g_re_ta	1157	20	1,70%	2	0,17%
v_vol250	1152	25	2,12%	2	0,17%
		302		688	

Respecto de las ratios con mayor concentración de datos vacíos, los siguientes son los comentarios del análisis:

- la ratio de volatilidad tiene todos los missing values que tratan de compañías nuevas, cuyo cálculo en base a un promedio móvil no es posible;
- la ratio de rentabilidad g_re_ta no tiene concentración sectorial, por lo que no existe evidencia de algún sesgo, y
- las ratios de liquidez si presentan una concentración sectorial, por lo que serán abordados a continuación. La tabla que a continuación se expone muestra la distribución por variables de datos igual a cero y vacíos.

Al segmentar por rating los datos presentados en la Tabla 32 se aprecian similares distribuciones, excepto en el rating D, donde los datos vacíos son más relevantes (ver la Tabla A 40 del Anexo C). Al segmentar los datos por sector industrial (ver Tabla A 42 del Anexo C), se pueden observar algunas concentraciones. El sector que aglomera la mayor cantidad de missing values es CYSER (*Cyclical Services*), donde las variables de liquidez tienen el mayor número de missing values (ver Tabla 33). Para CYSER, en cada una de las variables l_cas_ta , l_cas_cl y l_i_tca tiene un 61% de valores

ausentes. Las otras variables evaluadas para los casos de datos vacíos y con valor igual a cero, siguen patrones aleatorios.

Tabla 33. Distribución de missing values de algunas ratios por sector industrial

C_indc3	L_cas-ta		C_indc3	Nº datos totales y su %	
BASIC	1	4%	BASIC	161	14%
CYCGD	1	4%	CYCGD	84	7%
CYSER	14	61%	CYSER	263	22%
GENIN	1	4%	ITECH	106	9%
ITECH	1	4%	NCYCG	153	13%
RESOR	3	13%	NCYSR	88	7%
UTILS	2	9%	RESOR	112	10%
Total general	23	100%	UTILS	95	8%
			Total general	1177	100%

C_indc3	L_cas-cl	
BASIC	1	4%
CYCGD	1	4%
CYSER	14	61%
GENIN	1	4%
ITECH	1	4%
RESOR	3	13%
UTILS	2	9%
Total general	23	100%

L_i-tca	N/A	
C_indc3	L_i-tca	
BASIC	1	4%
CYCGD	1	4%
CYSER	14	61%
GENIN	1	4%
ITECH	1	4%
RESOR	3	13%
UTILS	2	9%
Total general	23	100%

Por último, para evaluar la relevancia general de los missing values y su aleatoriedad se exponen a continuación dos tipos de pruebas: a) la evaluación de significancia estadística de los datos ausentes y b) el análisis de las correlaciones generadas por la presencia de missing values. El test MCAR de Little, sugerido para el primer caso (Hair et al., 1999), revela que el nivel de significación es nulo, por lo que, a nivel global, los missing values pueden considerarse aleatorios. Para la segunda prueba, siguiendo a Hair et al. (1999) y Martínez (1999), se pueden observar los resultados del análisis de las correlaciones de pares de las variables dicotomizadas que indicaban la presencia o no de missing values en la Tabla A 39 del Anexo C. Para ello, se crea una variable dummy para cada variable a testear y luego se calculan las correlaciones de dichas variables indicatorias. De esta prueba se puede observar que sólo en las correlaciones intra-área de las variables existe una notoria y alta correlación entre missing values. Esta elevada correlación es aun más notoria en las correlaciones intra-área de liquidez, y en menor grado, de rentabilidad. Las restantes correlaciones, por ejemplo entre pares de variables de liquidez con aquellas de rentabilidad, son todas cercanas a cero. En otras palabras, esta prueba indica que (1) a nivel global se puede percibir aleatoriedad de datos ausentes y (2) que si bien, en la agrupación de variables intra-área, las correlaciones de los missing values tienen un valor elevado no se puede descartar del todo si siguen o no un proceso aleatorio; esto debido a que se debe a que algunas variables se calculan sobre la misma base contable y por ello es que ocurre la ausencia repetida de datos en algunas variables intra-área. Debido a que las correlaciones fuera de la zona intra-

área son bajas, se puede decir que con un nivel de significatividad del 5% no hay pruebas suficientes para pensar que los datos ausentes no siguen un proceso aleatorio.

4.5 Depuración de la muestra para replicar el rating en esta tesis

De acuerdo a la revisión de los datos de la muestra y con la mira puesta en cumplir los objetivos propuestos en esta tesis, al igual que en los capítulos anteriores, el autor formula una depuración a la muestra de datos para el proceso de réplica de rating y una propuesta para implementar en la réplica. Esta depuración se hace luego de haber constatado que la muestra de datos obtenida para la réplica es adecuada debido a que cumple los requisitos comunes para la finalidad, no está sesgada y es completa.

- ✓ **Depuración. Limpiar efecto de valores ausentes:** A pesar de que se encontró que los valores ausentes no tienen efectos generales significativos, se propone eliminar los casos que contengan valores ausentes en vez de calcular, con algún supuesto, el valor de éstos; con esta medida el tamaño cambia de 1177 a 1076 casos.

- ✓ **Propuesta. Construir dos conjuntos de datos con las variables que ayudarán a replicar el rating:** a pesar de que los SVM no tienen problemas con el tratamiento de la multicolinealidad y de los datos muy extremos, pero si existen evidencias ambas situaciones, sobre todo la colinealidad entre las variables intra-área, se sugiere la creación de dos conjuntos de datos: uno que contenga todas las variables y el otro que tenga un conjunto reducido de ellas. Para ello, los criterios de elección de variables serían los siguientes:
 - Para eliminar el problema de la influencia de los valores extremos se recomienda excluir las variables l_s_wc , f_td_ce , l_wc_ta , f_fa_ce y f_ltd_ce , en este orden de preferencia.
 - Para reducir el problema de colinealidad se sugiere, primero, elegir sólo una o dos variables de cada grupo de variables (tamaño, actividad, financiamiento, liquidez, rentabilidad y volatilidad), y segundo, utilizar criterios estadísticos basados en la explicación de la varianza y/o de mayor entropía en el modelo para elegir qué variables incluir.

4.6 Resumen

En este capítulo se exponen los principales resultados del análisis exploratorio y descriptivo de la muestra de datos para replicar el rating en esta tesis. Este conjunto de datos finalmente contiene información del rating corporativo del año 2002 de 1076 compañías de países desarrollados. Esta tabla de datos contiene información financiera de las condiciones estructurales, de gestión y variabilidad bursátil de las compañías con rating.

El conjunto de datos de rating analizado tiene una variabilidad y heterogeneidad suficiente como para permitir que el rating pueda ser replicado. No se observaron anomalías significativas que perturben la interpretación de los resultados. 20 de las 32 variables financieras de la muestra tienen una clara relación con el rating asignado por S&P, por lo que estas variables pueden ser útiles para predecir esta calificación de riesgo de crédito. La interpretación de los missing values y los valores extremos es mucho más clara si los datos son agrupados por la industria de cada compañía. El país al que pertenece cada empresa también ayuda a mejorar la interpretación de datos, aunque en menor medida que la industria. Sin embargo, para la tarea de replicar el rating no se recomienda la segmentación por país o por industria debido al tamaño final de las submuestras y de los grupos desbalanceados para cada rating en la fase de entrenamiento o ajuste de la técnica elegida para replicarlo.

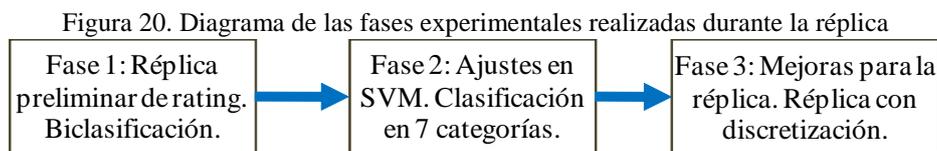
La mayoría de los datos pertenece a compañías de Estados Unidos (78%). Los valores de los estadísticos de centralidad y dispersión de las variables financieras son muy dispares. La mayoría de las variables distan mucho de ajustarse a una distribución normal, especialmente por sus altos niveles de curtosis. Las correlaciones entre las variables financieras intra-área son fuertes (valor absoluto mayor a 0,5) y las restantes correlaciones son débiles (valor absoluto menor a 0,3). Del examen de los estadísticos y los gráficos fue posible observar los siguientes aspectos particulares:

- se reafirman las distinciones entre los tipos de variables financieras, o sea, los grupos de variables que fueron realizados en función de criterios financieros (tamaño, actividad, financiamiento, liquidez, rentabilidad y volatilidad), se han visto reafirmados por las evidencias estadísticas,
- los grupos por países no presentan grandes discrepancias, salvo el caso de las compañías japonesas. Concretamente, las empresas de EUA y Canadá tienen muchas similitudes, y las diferencias con las europeas no son relevantes, y
- la separación por sector industrial genera conjuntos más homogéneos, aunque puede ser conveniente volver a reagruparlos en 4 o más supra-grupos. No obstante, este es un paso posterior a la réplica inicial del rating con los datos ya analizados.

Finalmente, a pesar de que los diferentes criterios para segmentar los datos ofrecieron mejoras para capturar información relevante, aun quedan muchos valores extremos de compañías que permanecen lejanas de los conjuntos más homogéneos. Esto no parece ser un inconveniente para el proceso de réplica con SVM, debido a las propiedades analizadas en el capítulo 3.

Capítulo 5. Aplicación de los SVM a la Réplica del Rating

El principal objetivo de esta tesis es replicar el rating crediticio de compañías utilizando SVM. Para esta finalidad se han utilizado las sugerencias de los capítulos 2, 3 y 4. Se ha elegido un conjunto de variables que, de acuerdo a la literatura revisada, podrían permitir replicar la calificación crediticia. Se ha centrado la atención en compañías de un grupo de países desarrollados, cuyos datos se han mostrado y evaluado en el capítulo anterior. Los ratings utilizados y que se intentan replicar se han agregado de dos maneras. Por una parte, se tienen todos los ratings separados en sólo dos conjuntos: un grupo tiene compañías cuyas calificaciones son de grado de inversión (AAA, AA, A y BBB), y el otro grupo con compañías que tienen rating de grado especulativo (BB, B, C y D). La otra manera de agrupar los datos de rating es a través de 7 clases: AA-AAA, A, BBB, BB, B, C y D. Los ratings de tipo AA y AAA se han juntado en una sola clase debido al número de datos existentes y a la similitud entre sus apreciaciones de riesgo. Del total de compañías de esta base de datos se han omitido aquellas que poseían missing values, reduciendo finalmente la muestra a 1076 casos. La caracterización completa está en el anterior capítulo.



El trabajo de réplica ha incluido 3 fases, donde la primera de ellas ha tenido por objetivo realizar las primeras pruebas de clasificación y evaluar el desempeño inicial de dicha réplica. La segunda fase ha incluido todos los ajustes necesarios para realizar la réplica final incluyendo ajustes tanto metodológicos como en la programación de algoritmos. En la última de las fases se han incorporado aquellas potenciales mejoras adicionales a la misma réplica.

Para replicar el rating de las empresas en la primera fase se han usado SVM biclasificadoras, debido a que se usó la primera de las agrupaciones de rating: con grado de especulación versus con grado de inversión. Para comparar el desempeño de los SVM se ha usado análisis discriminante y regresión logística. Luego, en la segunda fase se orientó la réplica de rating en 7 agrupaciones, junto a cambios en los procedimientos de selección de conjuntos de datos y de validación. A pesar de la posibilidad de usar SVM clasificatorias, se optó por el uso de SVR para incluir la ordinalidad de las clases en la réplica. La salida de datos en la SVR resulta un número perteneciente a \mathbb{R} , por lo que cada una de ellas ha sido recodificada en 7 clases (al entero más próximo de 1 a 7).

En la tercera fase del diseño empleado para replicar rating se ha incluido una alternativa que se valoró como una potencial mejora: se han utilizado discretizaciones en las variables explicativas bajo la suposición de que ésta puede mejorar la eficiencia de la réplica de rating. Se pretende evaluar si los SVM pueden *imitar* lo que los expertos financieros hacen inconscientemente antes de entregar su opinión crediticia, es decir, si los SVM con capaces de reproducir la categorización y contextualización de la información que extraen de las compañías que luego califican.

5.1 Metodología utilizada para replicar

A continuación se describen los distintos pasos que constituyen el proceso metodológico seguido en la réplica del rating, tanto para el caso de la biclasificación como para la réplica del rating en 7 clases. Diversos artículos y libros han servido para inspirar esta metodología propuesta en esta tesis, entre algunos de ellos Desai et al. (1996), Koh (1992), Kohavi (1995), Hair et al. (1999), Galindo y Tamayo (2000), Witten y Frank (2000), Chang y Lin (2001), Fan, Chen y Lin (2005).

5.1.1 La selección de las variables

Para replicar los ratings corporativos de las empresas, y siguiendo la literatura revisada, se han seleccionado las variables más apropiadas para predecir el rating, siguiendo las sugerencias propuestas al final de los capítulos 2, 3 y 4. Concretamente, para replicar este rating se han utilizado dos conjuntos de variables (ver Tabla 34):

- El primer conjunto es extensivo y recoge 32 ratios financieros y que se presentan bajo el nombre de Modelo 1, o bien, M1.
- En el segundo conjunto se selecciona a sólo 10 ratios, de entre los 32 anteriores, intentando que resulte ser más parsimonioso, capturando el mismo tipo de información de las compañías (tamaño, actividad, financiación rentabilidad, liquidez y volatilidad). Los resultados de la réplica con estos 10 ratios se presentan bajo el nombre de Modelo 2, o bien, M2.

Tabla 34. Ratios económico-financieros.

	Nombre	Descripción	Modelo 1	Modelo 2
Tamaño	t_vtas	Net Sales or Revenues	Si	Si
	t_vm	Market Capitalization	Si	
Actividad	a_s-ta	Sales / Total Assets	Si	Si
	a_cf-s	Cash Flow / Sales	Si	
	a_vvtas	Net Sales (del año en curso) / Net Sales (del año anterior) -1	Si	
Financiación	f_cf-td	Cash Flow (from Op.activ.) / Total Debt	Si	
	f_ltd-ce	Long Term Debt / Common Equity	Si	
	f_fa-ce	Fixed Assets / Common Equity	Si	
	f_td-ta	Total Debt / Total Assets	Si	Si
	f_dp-e	Dividend Payout / Earnings = (Common Dividends (Cash) / (Net Income before Preferred Dividends - Preferred Dividend Requirement)	Si	
	f_mv-e	Market Value Equity / Book Value of Total Liabilities	Si	Si
	f_td-ce	Total Debt / Common Shareholders Equity	Si	
Liquidez	l_s-wc	Net Sales / Working Capital	Si	
	l_wc-ltd	Working Capital / Long Term Debt	Si	
	l_wc-ta	Working Capital / Total Assets	Si	Si
	l_cl-ta	Current Liabilities / Total Assets	Si	
	l_quick	Quick Ratio = (Cash & Equivalents + Receivables (Net)) / Current Liabilities Total	Si	
	l_cas-ta	Current Assets - Stocks / Total Assets	Si	Si
	l_cas-cl	Current Assets - Stocks / Current Liabilities	Si	
	l_ca-cl	Current Assets / Current Liabilities	Si	
	l_c-cl	Cash & Short Term Investments/Current Liabilities	Si	
	l_i-tca	Inventories / Total Current Assets	Si	
	l_ca-ta	Current Assets / Total Assets	Si	Si
	l_cl-tl	Current Liabilities / Total Liabilities	Si	Si
Rentabilidad	g_ebit-i	EBIT / Tot Int Expense	Si	
	g_nia-ta	Net Income Available to Common / Total Assets	Si	
	g_ebit-s	EBIT / Sales	Si	
	g_ronfa	Return On Net Fixed Assets	Si	
	g_ebit-a	EBIT / Total Assets	Si	Si
	g_roe	Return On Equity	Si	
	g_re-ta	Retained Earnings / Total Assets	Si	
Volatilidad	v_vol250	Volatility of 250 days of stocks	Si	Si

La primera columna se refiere al tipo de variable; la segunda columna es el nombre de la variable, la tercera la definición de la construcción de los ratios a partir de las variables básicas de balance y cuentas de resultados; la cuarta columna especifica cuáles son las variables incluidas en la especificación de Modelo 1, y la quinta las incluidas en la especificación de Modelo 2.

La elección de estas variables ha sido eminentemente financiera. La idea central es que las variables de la muestra contribuyen en algún grado a explicar la calidad crediticia de las empresas y, por tanto, el rating. Dada la revisión de la literatura se ha podido reconocer la relación que tiene potencialmente cada variable elegida en la muestra y el rating. En la Tabla 35 se expone un ejemplo de este tipo de relaciones, tanto si ésta es teórica como práctica. El listado completo de todas las variables con las relaciones que les vinculan con el rating se encuentra en la Tabla 16 del capítulo 2.

Tabla 35. Ejemplo de las relaciones que hay entre las variables y el rating

nombre	concepto	relación con rating		motivo que respalda la interpretación financiera
		empírica	teórica	
L_quick	liquidez	no determinada	directa	indica la proporción de recursos líquidos que tiene la compañía para pagar las deudas de corto plazo, por lo que el aumento del ratio disminuye el riesgo de impago
L_cas-ta	liquidez	no determinada	directa	indica la proporción de recursos líquidos, descontado el inventario, respecto del tamaño de la compañía, por lo que el aumento del ratio disminuye el riesgo de impago

Para la selección de las variables se pretende presentar una aproximación más resumida, pero que a priori se cree que tiene similar calidad predictiva o de réplica del rating. Inicialmente, el primer criterio que se asume para elegir cuales serán las 10 variables más relevantes ha sido eminentemente

financiero, basado en la revisión bibliográfica y la experiencia del autor de esta tesis. Se ha seleccionado para este M2 al menos una variable de cada grupo de variables, léase tamaño, actividad, financiación, rentabilidad, liquidez y volatilidad, con la finalidad de que se capture la mayor cantidad de información contenida en las variables. Se ha elegido un mayor número de variables de liquidez para M2, debido a que las agencias de rating enfatizan en que este es uno de los puntos más relevantes y críticos para que sus grupos de expertos evalúen y califiquen a las compañías. Le sigue en importancia relativa el grupo de financiación, ya que este también es un aspecto relevante para dichas agencias.

Además de la justificación teórico-financiera que se ha usado para la elección de las variables de M2, se ha tenido en cuenta algunos criterios estadísticos. En esta línea, la colinealidad es un aspecto que se tomó en cuenta para la tarea de clasificación y réplica. Hair et al. (1999) menciona 3 opciones de adoptar frente a este problema: (a) la omisión de una o más variables en el modelo que tengan una colinealidad alta, cuidando no eliminar variables relevantes; (b) utilizar el modelo completo (con variables colineales) sólo para predecir y no para explicar el comportamiento o relaciones entre las variables; y (c) utilizar algún método más sofisticado que una simple regresión para obtener un modelo que refleje más claramente los efectos simples de las variables independientes, como por ejemplo alguna técnica de IA.

Para evaluar el efecto que tiene la multicolinealidad y el poder que tiene cada una de las variables para explicar el rating, se utilizan diversas metodologías. Por ejemplo, en modelos multivariados se utilizan diversos criterios de parada para evaluar hasta qué grado la contribución que cada variable hace a la explicación de la varianza de una variable dependiente es acertada. En este caso, para M2 se han usado dos tipos de enfoques para determinar cuáles de ellas pueden permitir replicar el rating con mayor confianza o poder explicativo. Un enfoque está basado en las diferencias que presentan los casos (las empresas) utilizando técnicas estadísticas que permiten realizar esta tarea. Concretamente, en la Tabla 36 se observan variables que han quedado seleccionadas con los siguientes criterios: L de Wilks, Varianza residual no explicada, la distancia de Mahalanobis y el estadístico F. En cada uno de estos criterios se observan, a su vez aquellas variables que han sido incluidas en M2. Las celdas verdes (o de color más oscuro) indican que la variable está en todas las selecciones de esta comparación; en cambio, las celdas amarillas (resaltada, pero levemente) indican que esta variable sólo está en ese criterio de selección. El otro enfoque se basa en la técnica de árboles de decisión (decision tree, DT) que incluye un proceso de optimización matemática para categorizar datos. Específicamente, se ha usado, como técnica de DT, una CART binomial ordinal porque ha dado mejores resultados en la

relación de entropía-información que las alternativas disponibles (CHAID, Exhaustive CHAID y C 5.0²⁶). Este procedimiento se ha realizado con SPSS versión 17.

Tabla 36. Criterios estadísticos para incluir variables a un modelo de réplica de rating.

Lambda de Wilks	Estadístico L-Wilks	Varianza No Explicada	Varianza residual	Distancia de Mahalanobis	Estadístico de Dist.Mah.	Menor valor de F	Estadístico F	CART-Bin.ord.	Importancia norm. >35%
v_vol250	0,4613	v_vol250	10,92032	v_vol250	0,033176	l_cl_ta	2,406024	T_VM	100,0%
T_VM	0,3231	T_VM	8,38746	T_VM	0,296328	T_VM	4,870895	v_vol250	95,1%
g_re_ta	0,2938	g_re_ta	7,89089	l_cl_tl	0,368461	v_vol250	9,201110	f_dp_e	90,3%
l_wc_ta	0,2684	l_wc_ta	7,63978	a_s_ta	0,442619	f_mve_tl	9,664412	g_re_ta	75,8%
f_td_ta	0,2524	f_td_ta	7,39538	f_mve_tl	0,503950	a_s_ta	9,960298	g_ebit_i	55,3%
l_cas_ta	0,2413	l_cas_ta	7,23843	l_wc_ta	0,565680	g_re_ta	8,856214	T_VTAS	53,6%
f_mve_tl	0,2329	f_mve_tl	7,13173	g_re_ta	0,574842	g_ebit_a	7,911173	g_ebit_s	53,5%
f_fa_ce	0,2249	T_VTAS	7,04615	T_VTAS	0,575932	f_td_ta	7,149226	g_ebit_a	49,7%
l_i_tca	0,2175	f_fa_ce	6,96604	f_td_ce	0,576647	l_cas_ta	7,938758	g_ronfa	46,8%
g_ebit_a	0,2117	l_i_tca	6,90767	f_fa_ce	0,577323	T_VTAS	7,147715	f_mve_tl	40,7%
T_VTAS	0,2065	g_ebit_a	6,86252	f_td_ta	0,577681	g_roe	6,496576	f_ltd_ce	39,1%
				g_ebit_a	0,577795	l_wc_ta	5,951270	f_cf_td	37,6%
				l_i_tca	0,577901			f_td_ce	37,4%
								f_fa_ce	36,0%

NOTAS: En los criterios estadísticos se estableció un punto de corte, tal que fuere significativo (al 5%), por lo que en esta tabla sólo incluye aquellas variables cuyo grado de explicación es significativa. En cambio, para el criterio CART, basado en la entropía, se obtiene un parámetro que mide la importancia que tiene cada variable. En este caso se usó el criterio de exponer aquellas variables cuya importancia normalizada fuese mayor al 35%.

5.1.2 Técnicas empleadas para replicar el rating

Tal como ya se ha planteado, en la fase 1 se han usado diversas técnicas con fines clasificatorios, que han permitido aprender acerca del trabajo mismo de la réplica. En dicha oportunidad se tomó la totalidad y se usó el procedimiento de validación cruzada de 2-carpetas. Una vez que se obtuvieron las mejores combinaciones de parámetros (tanto en la SVM como en las técnicas estadísticas), se reordenaron estratificada y aleatoriamente los datos para volver a segmentar las carpetas con distintos datos, y se repitieron los sucesos de las réplicas en 10 oportunidades. De este proceso se obtuvieron promedios de los estadísticos que permitieron evaluar la bondad de las réplicas llevadas a cabo. El objetivo de esta fase es comparar los desempeños obtenidos con los SVM clasificatorios usados y los pasos necesarios para la siguiente fase.

Por otra parte, en la fase 2 se ha separado del total de la muestra un 30% de los datos para dejarlos como validación o test. El restante 70% de los datos se ha usado para realizar diferentes tipos de análisis relativos a los SVR y sus kernels. En este bloque de datos de entrenamiento se han usado diferentes conjuntos de parámetros que pudiesen llevar a la mejor réplica. En una primera oportunidad, se realizaron réplicas para muchos valores de los parámetros, sin realizar sucesivas iteraciones. Una vez que se estableció un área más limitada de los conjuntos de parámetros que pudiesen llevar a una mejor tarea de réplica, se usaron repetidas iteraciones para encontrar la más eficiente SVR. Una vez que se obtuvieron las combinaciones más eficientes de parámetros en los SVR y en las técnicas

²⁶ Respecto del algoritmo C5, CHi-squared Automatic Interaction Detector (CHAID) y Classification and regression trees (CART) revisar el capítulo 3 respecto de árboles dedecisión.

estadísticas, se ha realizado la réplica en el conjunto de datos que se ha dejado fuera y no se ha usado en el entrenamiento.

En esta segunda fase, en ambos conjuntos de datos se han realizado tareas de evaluación de las diversas medidas de bondad de la predicción usando el procedimiento de 10-cv. En todo momento, se ha tenido en cuenta los dos siguientes objetivos:

- Comparar la capacidad de ajuste o entrenamiento de las técnicas, basada en estadísticos de bondad de la predicción con 10-cv
- Evaluar la capacidad de las técnicas para predecir el rating en un diferente conjunto de datos, que aunque es homogéneo al primero, no tienen exactamente los mismos patrones; concretamente, se trata de datos de diferentes empresas para el mismo año 2002.

Para todas las fases se han usado junto a los SVM cuatro kernels ampliamente usados en la literatura:

- a) un kernel lineal tal que $K(x_i, y_i) = x_i^T y_i$
- b) un kernel polinomial tal que $K(x_i, y_i) = (\gamma x_i^T y_i + r)^d$, $\gamma > 0$
- c) un kernel gaussiano o de base radial tal que $K(x_i, y_i) = \exp(-\gamma \|x_i^T y_i\|^2)$, $\gamma > 0$
- d) un kernel sigmoide tal que $K(x_i, y_i) = \tanh(\gamma x_i^T y_i + r)$

donde x_i corresponde a una matriz de variables que representan las características de las compañías, y_i es la variable representativa del rating crediticio. Los parámetros evaluados para los kernels mencionados fueron los siguientes: un coeficiente gamma (γ) directamente vinculado a las variables a través de su producto, un coeficiente cero o constante (r) que se añade aditivamente en el kernel a las variables y el grado de la función núcleo polinomial (d). Además, se ha incluido en este análisis de parámetros la sensibilidad del coste (C) del entrenamiento o sobreajuste, donde $C > 0$ es una constante asociada a la holgura que se permite en los SVM. En la medida que $C \rightarrow 0$, la SVM permitirá más errores en el proceso de aprendizaje; mientras que si $C \rightarrow \infty$, la SVM permitirá menores errores y ajustará al máximo la función a los datos de entrenamiento, causando, en algunos casos, sobreajuste y escaso grado de generalización. El software sobre el cual se ejecutaron los cálculos fue R 2.13.2 (R Development Core Team, 2005) y la librería que contiene la SVM utilizada es “e1071” de Meyer (2011) y propuesta en Chang y Lin (2001) y Fan, Chen y Lin (2005).

También se han usado dos técnicas estadísticas ampliamente usadas para clasificación en el ámbito de riesgo crediticio: AD y regresión logística. Para este caso se ha usado inicialmente SPSS 17.0 y luego se han implementado rutinas R 2.13.2 con la librería MASS 7.3-17 (Ripley, Kurt, Gebhardt y Firth (2012)). Se han usado los parámetros más usados que hacen más robustos y confiables los estadísticos para ambas técnicas. Por ejemplo, en AD se han calculado las probabilidades previas según los tamaños de los grupos y para regresión logística ordinal el modelo de efectos principales, con criterios de convergencia de parámetros relativamente amplios para que no se produzcan problemas cuando se

usa M1²⁷, debido a que se usan 32 variables explicativas del rating. También se han revisado los principales supuestos necesarios para ambas técnicas estadísticas. Los detalles se encuentran en el Anexo D.

5.1.3 Cuantificación de la bondad de la réplica.

La principal forma de evaluar el desempeño de la réplica de los ratings ha sido a través de la tasa de aciertos respecto del rating original. Esta decisión se debe a que es el principal indicador para evaluar la bondad de la réplica del rating en diversos artículos (Garavaglia, 1991; Kim, Weistroffer y Redmond, 1993; Maher y Sen, 1997; Shin y Han, 2001; Huang et al., 2004; Lee, 2007; Ahn y Kim, 2011). De hecho, en la fase 1 sólo se ha utilizado el porcentaje de aciertos global o total como herramienta de evaluación de la réplica. No obstante, también se han calculado para las fases dos y tres otros indicadores. Se han obtenido como estadísticos el RMSE²⁸, los porcentajes de error de sobrestimación y de subestimación del rating, y el cociente entre estos dos últimos porcentajes para evaluar la simetría del error de réplica del rating.

Tanto el error en la réplica como su simetría también han sido calculados por niveles o lejanía a la clase o rating real. Los casos en que el error corresponde a un solo salto de las 7 clases de rating (por ejemplo la distancia entre A y BBB) son considerados como errores de nivel 1. Se han distinguido 4 niveles de error en la medida que la réplica aleja del valor correctamente replicado (la diagonal en la tabla). En la Tabla 37 aparece un caso concreto de réplica donde los errores de nivel 1 subvaluados están en color más oscuro y suman en total 222 casos (equivalente al 21% de los datos a replicar). Para esta réplica con el M1 se ha usado una SVR con kernel sigmoide, gamma igual a 0,00001, costo igual a 1000. En este ejemplo, los errores subvalorados de nivel 2 aparecen con un color menos oscuro y los de nivel 3 en las casillas coloreadas con el color menos intenso. Esta tipología de niveles de errores se usa tanto para los casos subvaluados como para los sobrevalorados. Desde estas tasas de errores sobrevalorados con distintos niveles también se han calculado los cocientes de simetría, que en el ejemplo ilustrado son de 1,14 y 0,58 para los niveles 1 y 2, respectivamente.

²⁷ Para este caso 200 fue el máximo número de iteraciones para estimación de parámetros, el máximo umbral de convergencia de parámetros igual a 0,000001, tolerancia para la singularidad igual a 0,001.

²⁸ El RMSE (Root-mean-square error) es una medida de uso frecuente de las diferencias entre los valores predichos por un modelo o un estimador y los valores realmente observados.

Tabla 37. Matriz de confusión para explicar los niveles de los errores de réplica.

		Réplica de rating						
		AAA-AA	A	BBB	BB	B	C	D
Rating real	AAA-AA	13	3	2	0	0	0	0
	A	19	33	15	2	0	0	0
	BBB	16	161	245	94	18	1	0
	BB	0	2	56	166	92	8	3
	B	0	0	0	8	61	16	6
	C	0	0	0	0	9	12	2
	D	0	0	0	0	3	2	8

	Nivel 1	Nivel 2	Nivel 3	Nivel 4
Total de errores de rating subvaluados:	222 (20,6%)	36 (3,3%)	4 (0,4%)	0 (0,0%)
Total de errores de rating sobrevaluados:	255 (23,7%)	21 (2,0%)	0 (0,0%)	0 (0,0%)

	S _{N1}	S _{N2}	S _{N3}	S _{N4}
Simetría por niveles	1,1486	0,5833	-	-

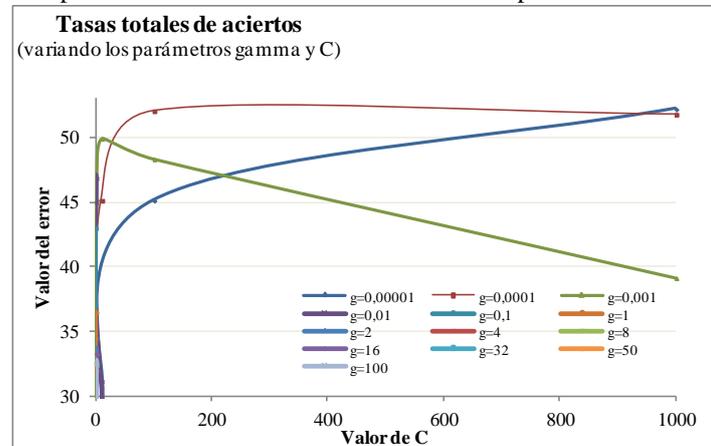
5.1.4 Calibración de parámetros en los SVM

Con los diferentes indicadores mencionados en el anterior punto para medir la eficiencia de los SVM, se probaron los diferentes kernels. Se usó inicialmente una extensa amplitud de valores para cada parámetro (γ , la constante r y C) y se analizó la sensibilidad que frente a estos cambios tenían los niveles de acierto, los diferentes tipos de errores y su simetría. El procedimiento para realizar el análisis siguió los siguientes pasos:

- 1°. Buscar el conjunto de parámetros que incrementa al máximo los niveles de acierto. Para este efecto primero se buscan las cotas superior e inferior que pueden tomar los parámetros, según el kernel elegido, y luego entre estos límites se establece un incremento pequeño de cada parámetro para evaluar las posibles tasas de acierto y error que se obtienen de la réplica (ver Anexo E). Este procedimiento se ha basado en las pautas de Hsu, Chan y Lin (2010) y Lin y Lin (2003).
- 2°. Luego de determinar el rango de los posibles valores de los parámetros, se han calculado las predicciones, utilizando 10-cv, y se ha medido sólo el nivel de acierto para cada una de las combinaciones posibles de los parámetros. A partir de este proceso se replican distintos conjuntos de parámetros para obtener uno o más conjuntos que maximizan las tasas de acierto. Los valores en los parámetros que visiblemente no proporcionan buenos niveles de acierto se desechaban. Por ejemplo, en la Figura 21 se observa que cuando gamma es igual 0,001 y C es mayor a 200, los niveles descienden drásticamente. Por lo tanto, este tramo de valores de gamma y C han sido desechados. Por el contrario, ante la existencia de rangos donde los niveles de acierto resultaron ser mayores para un mismo kernel, se han reordenados aleatoriamente los mismos datos para dividir en diferentes carpetas y realizar otras 10

iteraciones. Estos nuevos estadísticos calculados en el conjunto de datos de entrenamiento, se han promediado para una posterior comparación. La elección de esta figura ha sido meramente ilustrativa, ya que la exposición de estas gráficas para cada kernel no representa mayor interés. En cambio, en el Anexo E se presentan las gráficas para cada kernel usado.

Figura 21. Comportamiento de tasas de acierto al cambiar parámetros de un kernel radial



- 3°. Con los conjuntos de parámetros que resultaron ser más eficientes los SVM en el conjunto de datos de entrenamiento, se han usado los mismos SVM en el conjunto de datos de validación para evaluar si el grado de acierto era el esperado.
- 4°. Si el nivel de acierto es similar en el conjunto de entrenamiento y el de validación, se detiene el proceso de búsqueda de parámetros que hacen más eficiente el trabajo de réplica. En cambio, si hay bastante diferencia entre los niveles de acierto entre los conjuntos de datos (entrenamiento y validación), se evalúa la posible existencia de errores en la manipulación de los datos, o bien, la existencia de errores en el algoritmo. Luego se ha buscado otros conjuntos de parámetros que siendo relativamente eficientes en el conjunto de entrenamiento, pudiese encontrar menores errores en el conjunto de validación. En cada una de estas verificaciones finales, se cambian aleatoriamente los grupos de datos y se realizan 10 iteraciones. Este procedimiento se repite hasta encontrar un conjunto de parámetros que maximice las tasas de acierto. Un ejemplo de esta evaluación se expone en la Tabla 38, donde se puede observar un conjunto de valores de los parámetros y sus diferentes niveles de acierto. En el ejemplo, la mejor opción evaluada es con los parámetros $g=0,001$ y $C=10$, ya que se lograba un 49,93% de aciertos. Si una vez probados estos parámetros y kernel en el conjunto de datos de validación, la tasa de aciertos es significativamente más baja que este 49,93% habría que probar con las otras opciones que aparecen en la tabla y que tienen con una tonalidad un poco más oscura. Debido a la extensión de la cantidad de datos generados y al bajo nivel de interés que tendría observarlos, en esta tesis no se exponen las salidas de todos los datos relacionados con los indicadores y los conjuntos de parámetros. La Tabla 38 tiene la finalidad de ilustrar la manera en que se ha usado para encontrar los parámetros más adecuados para la réplica. Se ha optado por entregar un resumen de los conjuntos de parámetros más relevantes en la siguiente

sección (ver Tabla 42). En el Anexo E se exponen algunas tablas más representativas de la calibración de los SVR.

Tabla 38. Ejemplo de tasas de acierto según valores de parámetros de una SVR

cost\gamma	Gamma							
	g=0,00001	g=0,0001	g=0,001	g=0,01	g=0,1	g=1	g=2	g=4
0,00001	29,5606	29,5606	29,561	29,561	29,561	29,561	29,561	29,561
0,0001	29,5606	29,5606	29,561	29,561	29,561	29,561	29,561	29,561
0,001	29,5606	29,5606	29,561	29,561	29,561	31,957	32,357	32,357
0,01	29,5606	29,5606	29,561	29,827	43,009	36,485	33,688	32,89
0,1	29,5606	29,5606	29,827	45,007	34,487	4,261	4,5273	3,5952
1	29,5606	29,8269	45,273	46,871	6,3915	4,6605	2,2636	2,3968
10	29,8269	45,1398	49,933	31,159	3,0626	1,9973	2,3968	2,2636

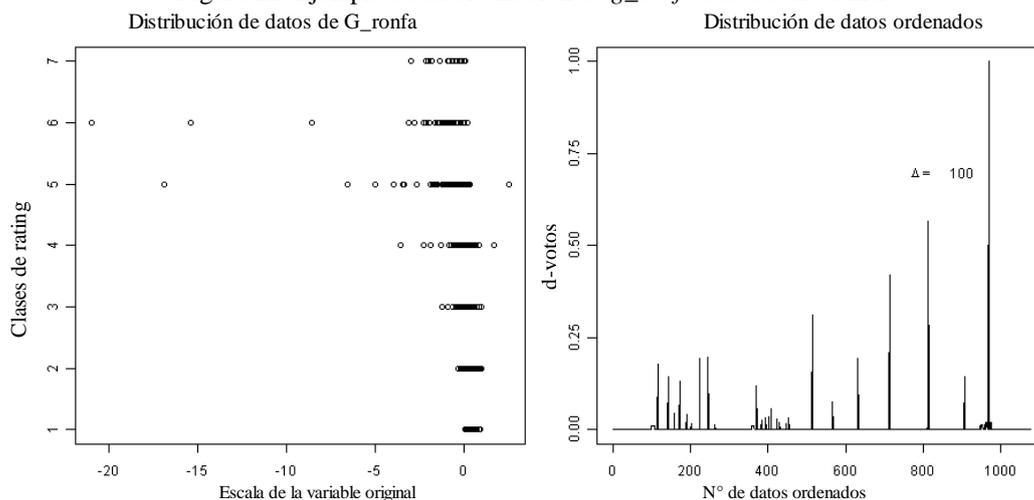
5.1.5 La discretización de variables

Un último paso es el que se ha planteado como la fase 3. Se ha evaluado el efecto que tiene la discretización de variables en la réplica de rating. Para discretizar los patrones se ha utilizado el método CAIM*, presentado en el capítulo 3, como método de discretización basado en la tabla de contingencia clase-intervalo. El proceso realizado en cada una de las pruebas fue el siguiente:

1. Se seleccionaron todas las compañías como patrones para la discretización (los 1076 casos).
2. Se procedió a la discretización de los patrones o variables explicativas del rating, supervisadamente respecto del rating con los 7 valores posibles.
3. Una vez encontrados los extremos de los intervalos en la discretización, se sustituyó cada valor de cada variable por un número entero asociado al intervalo correspondiente. Esto se realizó con todos los patrones, sin distinguir si éstos eran de entrenamiento o de test.

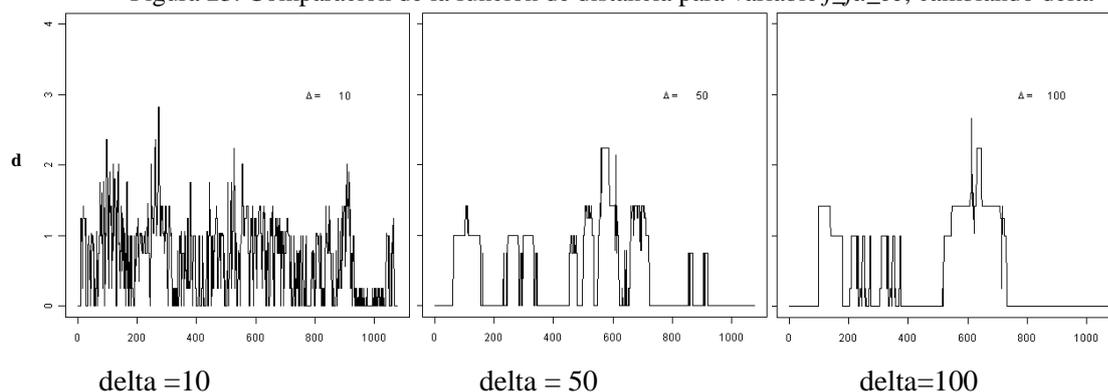
Esta discretización significa que todas las 32 variables empleadas para M1 y M2 se transforman y sustituyen por los valores discretos. En la Figura 22 se muestra el ejemplo de la variable g_ronfa (una variable continua que refleja la rentabilidad de la compañía medida sobre sus activos fijos). En la grafica de la izquierda de dicha figura se encuentra la distribución original de datos respecto de las clases de rating (en este caso 7 clases). Lo primero que se ha hecho es encontrar un vector de longitud n cuya posición i representa la distancia entre los intervalos de las salidas de los delta (Δ) patrones a la derecha y los delta patrones a la izquierda de i . En este caso se ha usado el rango intercuartílico y la distancia euclídea. En la gráfica de la derecha, la misma figura, se pueden observar los 1076 casos ordenados de esta variable g_ronfa , en donde se encuentran los límites de los intervalos, asumiendo un $\Delta = 100$. En grado de importancia, cerca del caso cercano a 950 se encuentra el punto más relevante donde generar un límite del intervalo.

Figura 22. Ejemplo de discretización de g_ronfa basado en CAIM.



En este método CAIM de discretización se han modificado sólo dos parámetros para encontrar los posibles intervalos para cada variable discretizada. Se han alternado los valores del umbral u y Δ ; tal que $u = \{0,3; 0,6; 0,9\}$ y $\Delta = \{10; 50; 100\}$. El efecto que tiene en la discretización el uso de estos valores incide en la cantidad de intervalos y su amplitud respecto de la variable supervisada (el rating). En la Figura 23 se presenta visualmente el efecto que tiene el cambio de valores del parámetro Δ en la variable f_fa_ce . Aquí se puede observar como este parámetro controla la granularidad media, de tal manera que un crecimiento del valor de Δ genera una disminución del número de intervalos finales. Esto también se puede verificar en la Tabla 39, donde se exponen los intervalos finales de todas las variables usadas en esta tesis.

Figura 23. Comparación de la función de distancia para variable f_fa_ce , cambiando delta



En la siguiente tabla se exponen 9 tipos de discretizaciones que se han usado en este estudio. Estas modificaciones en las variables se han hecho para ser implementadas en aquellos SVR que hayan tenido el mejor y el peor desempeño en la tarea de replicar el rating, respectivamente.

Tabla 39. Intervalos finales para cada variable discretizada con el método CAIM.

variable	delta = 10			delta = 50			delta = 100		
	u=0,3	u=0,6	u=0,9	u=0,3	u=0,6	u=0,9	u=0,3	u=0,6	u=0,9
t_vtas	53	8	3	17	10	3	10	3	2
t_vm	67	16	5	16	3	3	6	6	6
a_s_ta	74	41	6	16	9	2	7	3	2
a_cf_s	67	26	4	9	4	3	4	3	3
a_vvtas	63	26	4	15	5	4	8	6	3
f_cv_td	63	19	4	15	10	6	8	4	2
f_ltd_ce	15	3	3	4	3	3	4	3	3
f_fa_ce	67	22	5	9	5	2	7	4	3
f_td_ta	60	19	2	19	10	5	6	3	3
f_dp_e	30	7	3	5	3	2	4	3	3
f_mve_tl	70	36	7	10	3	3	6	4	3
f_td_ce	35	4	3	5	3	3	4	3	3
l_s_wc	59	15	2	9	4	3	9	3	2
l_wc_ltd	66	21	3	13	5	3	8	5	3
l_wc_ta	49	7	3	12	5	3	9	4	3
l_cl_ta	46	5	3	14	7	4	6	5	3
l_quick	69	31	4	16	11	8	8	3	2
l_cas_ta	68	28	5	14	9	5	11	5	4
l_cas_cl	59	20	4	14	10	3	8	2	2
l_ca_cl	53	5	3	19	12	4	9	5	4
l_c_cl	65	24	4	17	8	4	9	2	2
l_i_tca	68	30	3	14	7	3	7	3	2
l_ca_ta	62	19	5	19	13	6	10	5	4
l_cl_tl	71	30	3	16	9	5	9	4	4
g_ebit_i	60	13	3	17	7	3	6	6	3
g_nia_ta	74	27	4	16	6	3	9	6	3
g_ebit_s	51	13	3	14	7	3	5	4	3
g_ronfa	68	15	5	17	10	9	12	4	2
g_ebit_a	35	4	3	12	3	2	5	3	3
g_roe	75	37	5	10	3	3	6	3	3
g_re_ta	58	15	3	10	8	3	4	4	4
v_vol250	75	33	3	12	10	6	8	5	5

Luego de tener los datos discretizados, éstos remplazan a los valores originales de las variables, para ser utilizados en la réplica de rating. Los criterios para evaluar qué tipo de kernel y cuáles serán los parámetros son los siguientes:

- a) usar los kernels con el que se consiga mayor y menor nivel de acierto en la réplica. Por lo tanto, esto dará paso a replicar con dos funciones núcleo con la entrada de datos discretizados. En caso de que exista más de un kernel que cumpla con estas condiciones, se opta por los 2 kernels que tengan mejores/peores niveles de acierto.
- b) Los parámetros que se usen son aquellos que en la fase de calibración lograron que la SVR tuviese el mejor nivel de aciertos. En caso de ambigüedad en la elección de los parámetros, se elije aquel conjunto con el que se haya logrado mayor simetría en los errores.

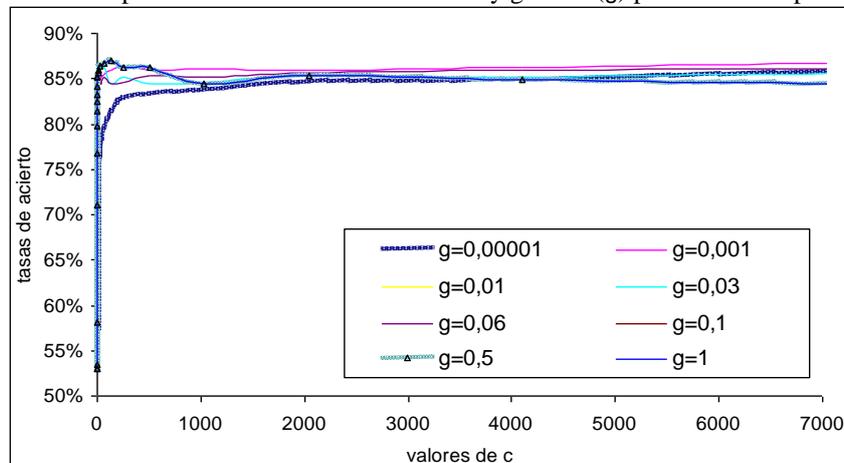
5.2 Resultados de la réplica de ratings

En esta sección se exponen los resultados logrados con la réplica de rating. Primero se exponen los resultados de la fase 1 con la biclasificación de rating; luego la réplica de rating con 7 clases logradas en la fase 2 y, por último, la evaluación del uso de discretización de datos para la réplica de rating.

5.2.1 Biclasiificación con SVM

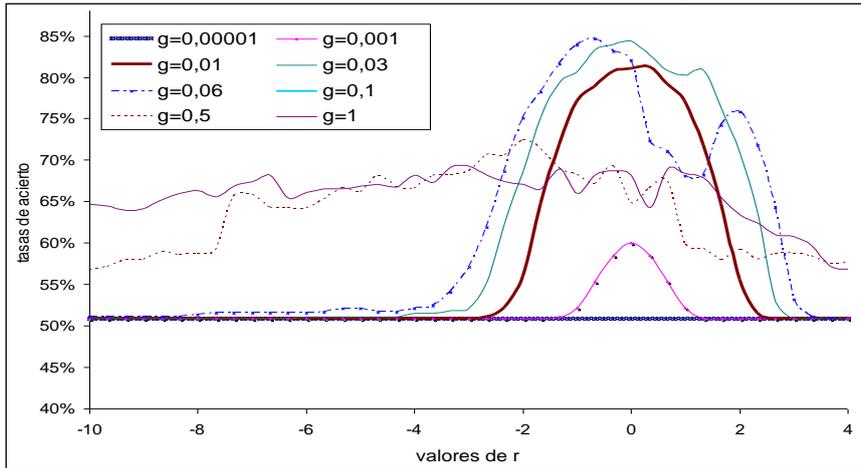
Para la tarea de replicar el rating se han evaluado diferentes valores para los parámetros de las cuatro SVM consideradas en el apartado 5.1.4 de este capítulo. Las tasas de acierto para el kernel lineal se logran mantener en un rango relativamente estrecho entre el 75% y 85% a pesar de que cambie C . Su óptimo se ha encontrado cuando $C=2,8$. En los kernels polinomiales el nivel de acierto aumenta considerablemente cuando C toma valores grandes, pero con un techo. Esta relación asintótica de la tasa de aciertos con este techo se presenta además en el kernel sigmoide y radial. En la Figura 24 se puede observar en la gráfica de tasas de acierto para un kernel polinomial de segundo grado como, a partir de que $C > 50$, no cambia mucho el nivel de aciertos a pesar de que gamma tome distintos valores. En general, para este kernel, si $C < 20$, entonces las tasas de acierto son significativamente inferiores (llegando al 53% de aciertos). Más evidencias de estas tasas de acierto con otros kernels se encuentran en el Anexo E.

Figura 24. Tasas de acierto para M2 a diferentes valores de C y gamma (g) para un kernel polinomial de grado 2.



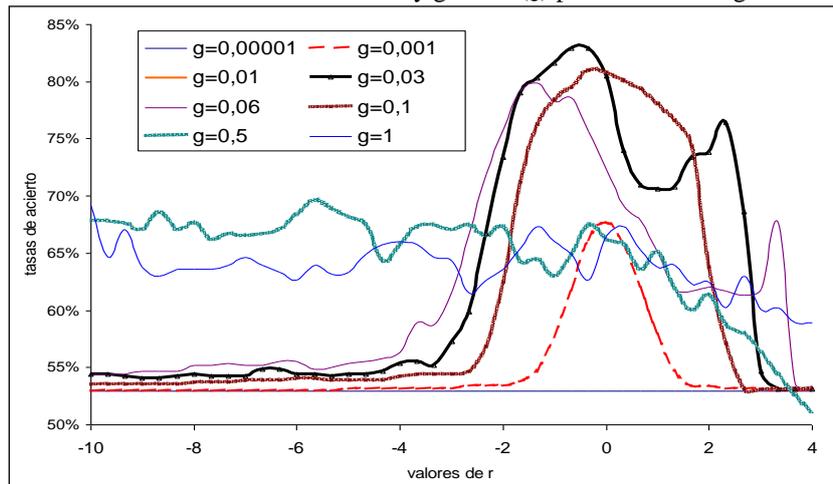
Por otra parte, en los kernels polinomiales y sigmoide, los valores que hacen más asertiva la predicción del rating tienden a cero. En la Figura 25 se expone la distribución de tasas de acierto con el kernel sigmoide, donde se observa que las mayores tasas de acierto, cambiando los valores de gamma (con la letra g en la gráfica), están entre -1 y $+1$.

Figura 25. Tasas de acierto para M2 a diferentes valores de r y gamma (g) para un kernel sigmoide.



Por otra parte, los rangos donde hay más elevadas las tasas de acierto son relativamente similares para M1 y M2. Es decir, tanto si se utilizan todas las variables de la muestra con si sólo se usan las 10 seleccionadas en el M2, los valores óptimos de los parámetros son semejantes. La comparación visual entre la Figura 25 y la Figura 26 ofrece una aproximación de cuan similares son las tasas de acierto de los parámetros.

Figura 26. Tasas de acierto a diferentes valores de r y gamma (g) para un kernel sigmoide con 32 variables.



La Figura 26 hace referencia a las tasas de acierto con el mismo kernel y parámetros que los usados en la Figura 25, pero utiliza M1 en vez de M2. En ambas se puede observar una cierta similitud con una forma de semi-campana en torno a $r=0$, cuando $g = [0,001; 0,1]$.

Una vez realizado el análisis de calibración de los parámetros en la fase 1 de la réplica de dos clases de rating (grado de inversión versus grado especulativo), con M1 y M2, los mayores niveles de acierto se pueden observar en la Tabla 40. En esta tabla se observa que las tasas de acierto con validación cruzada de 2 carpetas, usando todos los datos de la muestra, están en torno al 85%. De las funciones núcleo evaluadas, el kernel lineal y los polinomiales de grado 1, 2 y 3 son aquellos que ofrecen resultados predictivos levemente superiores al resto.

Tabla 40. Parámetros óptimos para distintos kernels para la biclasificación y sus tasas de acierto.

Kernel	parámetro			Aciertos	
	gamma	constante r	C	M1	M2
Lineal	-	-	2,8	86,13%	84,52%
Gausiano	0,008	-	8,0	85,23%	
	0,1	-	5,8		84,27%
Sigmoide	0,01	-0,28	3,0	82,78%	
	0,03	-0,28	1,8		83,63%
Polinomial grado 1	9,1	-	0,4	86,45%	84,89%
Polinomial grado 2	0,1	10,0	0,8	86,00%	85,09%
Polinomial grado 3	0,01	10,0	1,3	86,44%	85,39%
Polinomial grado 4	0,01	1,0	28,2	85,16%	84,66%
Polinomial grado 5	0,01	1,0	12,0	85,07%	84,57%
Polinomial grado 6	0,01	2,0	1,2	84,93%	84,63%

Para comparar las anteriores tasas de acierto, se ha utilizado AD y logit, usando el mismo procedimiento que con los SVM. Las tasas de acierto promedio fueron las siguientes:

Tabla 41. Tasas de acierto global con AD y logit en la tarea de biclasificación

	M1	M2
AD	75,86%	81,75%
Logit	85,74%	84,20%

NOTA: El AD es de tipo cuadrático (matrices de covarianza separadas) y sin diferenciación de tamaños muestrales por rating (dos clases). El punto de corte para la predicción grupal de logit fue de 0,5.

Se puede observar que para la réplica de dos clases de rating, los SVM pueden realizar dicha tarea con igual o mejor nivel de acierto. Al comparar los resultados de acierto de los SVM con los de AD, siempre fueron mayores las tasas de las primeras técnicas. Incluso, con el M1, en 7 de las 9 SVM la diferencia en las tasas de acierto fue de 10% o más. Esta diferencia no fue tan notoria al usar M2. En la comparación entre las tasas de acierto logradas con los SVM y las regresiones logísticas, no se pudo observar una gran diferencia. Aunque en la mayoría de ellas (12 de 18 réplicas con SVM) permiten obtener tasas de acierto levemente superiores a los obtenidos con regresión logística.

Con estos resultados y el aprendizaje de haber realizado estas réplicas se procedió a la fase 2 experimental de esta tesis. A continuación se exponen los resultados obtenidos con la réplica de rating en 7 clases.

En resumen, en esta fase 1 se han replicado los ratings con SVM clasificatorias, AD y regresión logística con M1 y M2, y se han buscado los conjuntos de los parámetros con los que se obtienen mejores tasas de acierto. En general, con los SVM se puede replicar adecuadamente los rating en dos clases y las tasas de acierto obtenidas son relativamente similares a las logradas con regresión logística. Sin embargo, las tasas de acierto obtenidas con SVM son mayores que las logradas con AD. Esta diferencia es más notoria cuando se utiliza M1. De los kernels usados para replicar, el lineal, el gausiano y el polinomial de grado 1, han sido aquellos con los que se han logrado mejores tasas de acierto.

Respecto de los parámetros usados para los diferentes kernel, cuando el parámetro constante r es igual a cero, la SVM tiende a replicar con mayores tasas de acierto. Si el parámetro C tiene un valor muy grande no se generan mayores tasas de acierto. Sin embargo, el coste computacional si es mayor.

Por último, un problema persistente es la falta del cumplimiento de supuestos estadísticos al usar AD. El supuesto de distribución binomial de los residuos de la regresión logística tampoco se ha cumplido. Los resultados de los test aparecen en el Anexo D. Sin lugar a dudas estos incumplimientos van en detrimento de las réplicas de rating.

5.2.2 Resultados de la réplica de rating con 7 clases

A continuación se exponen los aspectos más relevantes del análisis de la calibración de los parámetros de los SVR utilizados para la réplica del rating en 7 clases.

5.2.2.1 Análisis de sensibilidad para los parámetros de los SVR

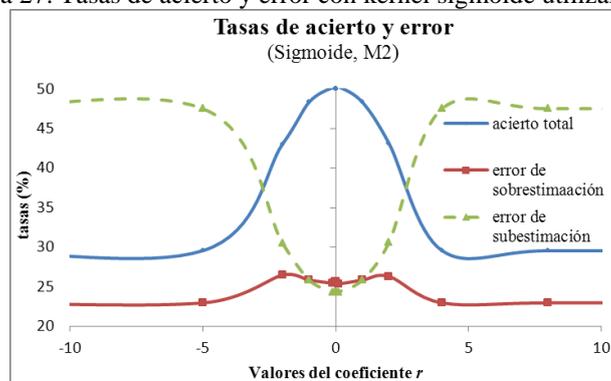
Cabe recordar que en esta fase, primero se realizaron evaluaciones de los parámetros sobre la muestra de entrenamiento, 10-cv, con una sola iteración. Luego se han usado conjuntos de parámetros más restringidos 10 iteraciones. Después de comprobar aquellos conjuntos que obtienen mejores estadísticos se han usado dichos parámetros para entrenar y validar los SVR en 30 oportunidades, dentro y fuera de la muestra. Siempre con la finalidad de obtener el mejor nivel de acierto, con el menor coste computacional. Respecto del coste computacional se verificó el excesivo consumo computacional para el entrenamiento y réplica de rating con kernel polinomiales de tercer o mayor grado. Por ejemplo, para replicar el rating de acuerdo a M2, sólo con el kernel polinomial de grado tres con $g=2$, $C=1$ y $r=0$, el trabajo de entrenamiento en un AMD Athlon 64 X2 de 1,90 Ghz duró 5 horas y 54 minutos. Aun más, en la validación realizada fuera de la muestra de entrenamiento, este kernel logró una tasa de aciertos máxima del 49%; muy similar a la lograda con el polinomial de grado uno y muy por debajo de las tasas logradas con el kernel radial, y en muchísimo tiempo menos. Este comportamiento de costo excesivo en el cálculo, desechó completamente la réplica de este grado polinomial.

Considerando sólo el proceso de entrenamiento de los SVR, la variabilidad de las tasas de acierto para cada conjunto de parámetros resultó ser menor cuando éste fue llevado a cabo con funciones núcleo radial y sigmoide. Es decir, si se eligen aleatoriamente distintos conjuntos de datos y se usa 10-cv, la tasa de acierto para cada conjunto de parámetros suele ser relativamente similar en cada una de las

iteraciones. En cambio, el kernel lineal presentó las mayores tasas de variabilidad en el pronóstico de rating. Por ejemplo, en el entrenamiento hecho para M1 con el kernel radial el coeficiente de variabilidad de las tasas de acierto fue del 0,68%, en cambio similar proceso llevado a cabo con el kernel lineal resultó 1,08%.

En general, los parámetros que hicieron más eficiente la réplica en la fase 1 también lo fueron en la fase 2. El caso más notorio ocurre con los valores de la constante r , ya que las mayores tasas de acierto se lograron cuando este parámetro tendía a cero, tanto en la fase 1 como en la fase 2. En la Figura 27 se puede observar como las tasas de acierto son máximas cuando este coeficiente es igual a cero, cuando se usó el kernel sigmoide. Particularmente, en este caso, el error de subestimación descendió fuertemente cuando $r=0$, aunque el error de subestimación subió levemente.

Figura 27. Tasas de acierto y error con kernel sigmoide utilizando M2



Por otra parte, los valores de los parámetros que se desecharon en la fase 1 debido a que lograban bajas tasas de acierto son relativamente los mismos obtenidos en esta fase 2. El comportamiento de los errores y tasas de acierto obtenidas con los valores de C y de γ también fueron similares a la fase 1. En la mayoría de los casos, los valores muy pequeños de estos parámetros no contribuían a la réplica adecuada de rating; no obstante, el coste computacional era más bajo.

Singularmente en los kernel radial y polinomial de grado 2 se ha producido un sobreentrenamiento cuando los valores de γ y C tomaron valores elevados, ya que las tasas de acierto en la validación cruzada 10-cv son extrañamente elevadas, pero no lo son en el conjunto de datos de validación. Esto se puede observar en la Tabla 42 y en la Tabla 43. En la primera de estas tablas se presentan todos los conjuntos de parámetros que resultaron relevantes, evaluados según la tasa de acierto total de las réplicas. Como se observa en esta tabla, usando el kernel radial si $C \geq 10$ y $\gamma \geq 0,1$, la tasa de aciertos con validación cruzada en el conjunto de datos de entrenamiento es del 100%. Sin embargo, al replicar los ratings con datos fuera de la muestra, con este kernel y con estos mismos parámetros, las tasas de acierto están entre el 37,95% y el 61,61%, dependiendo si se ha usado M1 o M2. Este mismo tipo de sobreentrenamiento ha ocurrido con el kernel polinomial de grado 2.

Por al contrario del sobreentrenamiento ocurrido con los kernel radial y polinomial de grado 2, los restantes kernel no presentaron esta desventaja. Especial particularidad cabe destacar la situación del kernel sigmoide, ya que además de no sobrentrenar ha logrado altas tasas de acierto para M1. Esto no ha sucedido para la réplica con M2; es decir, el entrenamiento logrado con este kernel y la subsecuente réplica, usando M2, genera menores tasas de acierto que el kernel radial (ver Tabla 43).

Otro aspecto que es importante de resaltar es que algunos conjuntos de parámetros producen errores bastante asimétricos. En la medida que el estadístico de simetría construido en esta tesis sea igual a uno, el error está relativamente equilibrado en ambos lados de la matriz de contingencia. El conjunto de parámetros que genera los mayores errores asimétricos fue al usar el kernel radial con gamma entre 1 y 4 y $C \geq 10$. Con estos parámetros y kernel la asimetría es de 0,56.

Tabla 42. Cuadro resumen de los rangos más relevantes para cada parámetro

Kernel	Modelo	Conjunto de datos	r	Gamma	C	A _m *	S _{Am} *
Lineal	1	entren.+10fcv	-	-	[0,0001 a 10]	63,36	1,12
Lineal	1	validac.fuera	-	-	0,00001	61,54	0,78
Lineal	1	validac.fuera	-	-	1000	60,24	1,33
Lineal	2	entren.+10fcv	-	-	[0,0001 a 1000]	49,20	0,92
Lineal	2	validac.fuera	-	-	[0,1 a 100]	47,64	0,79
Polinomial G1	1	entren.+10fcv	0	0,001	10	60,76	1,07
Polinomial G1	1	entren.+10fcv	[-0,00001 a 0,00001]	0,01	10	63,40	0,95
Polinomial G1	1	entren.+10fcv	[-0,00001 a 0,00001]	> 1	> 0,01	63,44	1
Polinomial G1	1	validac.fuera	[-0,00001 a 0,00001]	0,01	1	55,34	1,06
Polinomial G1	1	validac.fuera	[-0,00001 a 0,00001]	0,01	1	57,43	1,01
Polinomial G1	1	validac.fuera	[-0,00001 a 0,00001]	1	0,1	61,34	1,06
Polinomial G1	1	validac.fuera	[-0,00001 a 0,00001]	[2 - 4]	>= 1	58,07	1,12
Polinomial G1	2	entren.+10fcv	-0,0001	0,01	10	51,05	0,95
Polinomial G1	2	entren.+10fcv	0	0,1	1	50,30	0,96
Polinomial G1	2	entren.+10fcv	0	1	10	50,14	0,92
Polinomial G1	2	entren.+10fcv	-0,0001	2	1	50,12	0,89
Polinomial G1	2	validac.fuera	[-0,00001 a 0,00001]	1	[0,01 a 0,9]	53,94	1,18
Polinomial G1	2	validac.fuera	[-0,00001 a 0,00001]	2	10	51,70	0,86
Polinomial G2	1	entren.+10fcv	[-0,00001 a 0,00001]	1	>=1	100,00	no hay
Polinomial G2	1	entren.+10fcv	[-0,00001 a 0,00001]	>=2	>=0,1	100,00	no hay
Polinomial G2	1	entren.+10fcv	[-0,00001 a 0,00001]	2	10	57,10	1
Polinomial G2	1	validac.fuera	[-0,00001 a 0,00001]	0,1	0,1	52,23	1,14
Polinomial G2	1	validac.fuera	[-0,00001 a 0,00001]	2	[0,001 a 0,01]	57,06	1
Polinomial G2	2	entren.+10fcv	[-0,00001 a 0,00001]	>=0,1	>=10	42,43	1,3
Polinomial G2	2	validac.fuera	[-0,00001 a 0,00001]	1	10	39,2	1,24
Polinomial G2	2	validac.fuera	[-0,00001 a 0,00001]	>=0,1	>=10	40,17	1,35
Radial	1	entren.+10fcv	-	0,01	100	99,25	1,15
Radial	1	entren.+10fcv	-	>= 0,1	>= 10	100,00	no hay
Radial	1	validac.fuera	.	0,0001	>= 10	59,95	1,18
Radial	1	validac.fuera	.	0,001	>= 1	59,23	1,09
Radial	1	validac.fuera	.	0,01	>= 0,1	61,61	0,79
Radial	1	validac.fuera	.	0,1	>= 1	56,44	1,13
Radial	2	entren.+10fcv	-	0,1	>= 100	100,00	no hay
Radial	2	entren.+10fcv	-	[1 a 4]	>= 10	100,00	no hay
Radial	2	entren.+10fcv	.	>= 8	>= 1	100,00	no hay
Radial	2	validac.fuera	.	0,1	>= 100	49,24	0,76
Radial	2	validac.fuera	.	[1 a 4]	>= 10	45,83	0,56
Radial	2	validac.fuera	.	>= 8	>= 1	49,44	0,75
Radial	2	validac.fuera	.	0,08	>= 1	56,19	0,87
Radial	2	validac.fuera	.	0,25	>= 5	56,35	1,11
Radial	2	validac.fuera	.	0,33	>= 1	53,81	0,92
Sigmoide	1	entren.+10fcv	[-0,1 a 0,1]	0,00001	100	57,6	1,13
Sigmoide	1	entren.+10fcv	[-0,1 a 0,1]	0,0001	10	57,13	1,1
Sigmoide	1	entren.+10fcv	[-1 a 1]	0,0001	100	63,37	1,08
Sigmoide	1	entren.+10fcv	[-0,1 a 0,1]	0,001	1	58,03	1,11
Sigmoide	1	entren.+10fcv	[-1 a 1]	0,001	10	61,21	1,06
Sigmoide	1	entren.+10fcv	[-1 a 0,01]	0,001	100	67,01	1,01
Sigmoide	1	entren.+10fcv	[-0,1 a 0,1]	0,01	0,1	54,71	1,19
Sigmoide	1	validac.fuera	[-0,1 a 0,1]	0,00001	100	55,35	0,99
Sigmoide	1	validac.fuera	[-0,1 a 0,1]	0,0001	10	56,15	1,11
Sigmoide	1	validac.fuera	[-1 a 1]	0,0001	100	61,89	1,07
Sigmoide	1	validac.fuera	[-0,1 a 0,1]	0,001	1	56,16	0,86
Sigmoide	1	validac.fuera	[-1 a 1]	0,001	10	58,59	1,38
Sigmoide	1	validac.fuera	[-1 a 0,01]	0,001	100	56,87	0,94
Sigmoide	1	validac.fuera	[-0,1 a 0,1]	0,01	0,1	56,57	1,18
Sigmoide	2	entren.+10fcv	[-0,1 a 0,1]	0,0001	1 a 10	47,67	0,97
Sigmoide	2	entren.+10fcv	[-0,1 a 0,1]	0,001	10 a 100	50,67	0,89
Sigmoide	2	entren.+10fcv	[-0,1 a 0,1]	0,001	100	48,4	1,01
Sigmoide	2	validac.fuera	[-0,1 a 0,1]	0,0001	1 a 10	46,77	1,12
Sigmoide	2	validac.fuera	[-0,1 a 0,1]	0,001	10 a 100	45,16	1,05
Sigmoide	2	validac.fuera	[-0,1 a 0,1]	0,001	100	47,31	0,79

Nota: Para calcular estos estadísticos se han promediado los valores de 10 iteraciones con 10-cv. A_m* es la tasa de acierto más alta calculada para ese conjunto de parámetros y S_{Am}* es su simetría. En este último caso, aparecen ennegrecidos los indicadores de simetría que se encuentran una desviación estándar por debajo o por encima de la media.

Tabla 43. Resumen de tasas de acierto, errores y simetría para M1 y M2 utilizando diferentes funciones núcleo, tanto dentro como fuera del conjunto de datos de entrenamiento.

Lineal	M1					M2					
	Entrenamiento y 10-cv	RMSE	% acierto	% Error total		simetría	RMSE	% acierto	% Error total		simetría
				sobre	sub				sobre	sub	
Máximo	0,63	63,36	20,41	19,48	1,05	0,86	50,15	25,24	27,92	0,90	
Promedio	0,62	62,26	19,55	18,19	1,08	0,84	49,20	24,38	26,43	0,92	
Mínimo	0,60	60,66	18,78	17,27	1,09	0,82	48,46	23,44	25,48	0,92	
Validación fuera muestra		RMSE	% acierto	sobre	sub	simetría	RMSE	% acierto	sobre	sub	simetría
Máximo		0,80	61,54	23,06	22,00	1,05	0,92	48,99	28,44	31,04	0,92
Promedio		0,69	58,26	21,09	20,64	1,02	0,87	47,64	24,92	27,45	0,91
Mínimo		0,64	56,56	16,80	17,03	0,99	0,83	45,43	22,52	24,25	0,93
Polinomial Grado 1	M1					M2					
	Entrenamiento y 10-cv	RMSE	% acierto	% Error total		simetría	RMSE	% acierto	% Error total		simetría
				sobre	sub				sobre	sub	
Máximo	1,33	65,21	48,74	27,86	1,75	1,35	51,05	48,50	29,19	1,66	
Promedio	0,72	56,60	23,46	19,94	1,18	0,93	44,54	29,68	25,78	1,15	
Mínimo	0,60	28,51	17,36	16,83	1,03	0,80	28,93	23,07	22,15	1,04	
Validación fuera muestra		RMSE	% acierto	sobre	sub	simetría	RMSE	% acierto	sobre	sub	simetría
Máximo		1,51	62,85	49,08	29,77	1,65	1,38	53,94	49,88	30,62	1,63
Promedio		0,79	53,06	24,98	21,96	1,14	0,95	43,85	30,02	26,13	1,15
Mínimo		0,62	27,66	15,97	15,90	1,00	0,80	28,03	21,09	21,09	1,00
Polinomial Grado 2	M1					M2					
	Entrenamiento y 10-cv	RMSE	% acierto	% Error total		simetría	RMSE	% acierto	% Error total		simetría
				sobre	sub				sobre	sub	
Máximo	1,34	100,00	48,17	24,73	1,95	1,29	42,43	47,40	26,02	27,26	
Promedio	0,52	75,88	14,99	9,13	1,64	1,11	38,53	36,34	25,12	24,57	
Mínimo	0,12	28,67	0,00	0,00	-	1,02	29,62	32,30	22,98	21,57	
Validación fuera muestra		RMSE	% acierto	sobre	sub	simetría	RMSE	% acierto	sobre	sub	simetría
Máximo		139,28	57,06	49,65	32,86	1,51	1,98	40,17	46,83	31,78	28,51
Promedio		8,23	42,87	31,31	25,83	1,21	1,50	35,72	37,74	26,55	25,54
Mínimo		0,96	27,21	18,71	21,45	0,87	1,22	30,27	32,58	22,26	21,76
Radial	M1					M2					
	Entrenamiento y 10-cv	RMSE	% acierto	% Error total		simetría	RMSE	% acierto	% Error total		simetría
				sobre	sub				sobre	sub	
Máximo	1,36	100,00	48,37	28,12	1,72	1,36	100,00	48,42	27,94	1,73	
Promedio	0,95	51,31	31,73	16,96	1,87	0,85	55,40	27,30	17,30	1,58	
Mínimo	0,12	28,79	0,00	0,00	-	0,12	28,91	0,00	0,00	-	
Validación fuera muestra		RMSE	% acierto	sobre	sub	simetría	RMSE	% acierto	sobre	sub	simetría
Máximo		1,38	61,61	50,09	44,52	1,13	1,37	59,04	49,95	35,63	1,40
Promedio		1,20	36,27	37,94	25,79	1,47	1,11	39,54	34,14	26,32	1,30
Mínimo		0,63	26,94	16,17	18,37	0,88	0,76	26,61	19,22	21,09	0,91
Sigmoide	M1					M2					
	Entrenamiento y 10-cv	RMSE	% acierto	% Error total		simetría	RMSE	% acierto	% Error total		simetría
				sobre	sub				sobre	sub	
Máximo	10699,45	67,01	48,88	49,37	0,99	9945,06	50,67	48,51	49,24	0,99	
Promedio	276,73	29,52	42,80	27,68	1,55	493,68	26,57	43,05	30,38	1,42	
Mínimo	0,62	2,22	16,16	16,83	0,96	0,82	2,53	23,29	22,46	1,04	
Validación fuera muestra		RMSE	% acierto	sobre	sub	simetría	RMSE	% acierto	sobre	sub	simetría
Máximo		10172,23	61,89	54,09	54,75	0,99	10033,17	47,31	55,70	51,51	1,08
Promedio		266,12	29,28	42,86	27,86	1,54	493,96	26,46	43,36	30,18	1,44
Mínimo		0,63	1,22	19,09	17,37	1,10	0,86	1,62	23,29	21,93	1,06

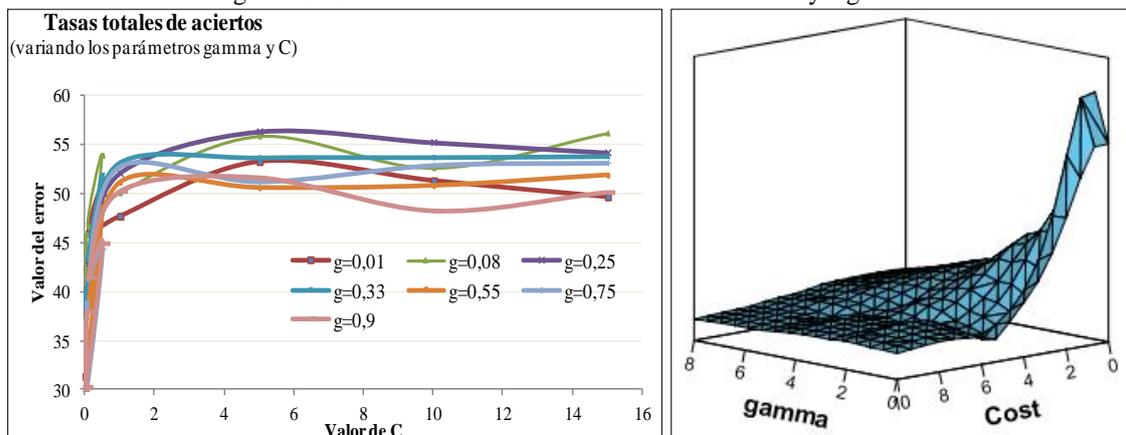
Con la información de la Tabla 43 se puede observar que muchos de los valores posibles de los parámetros pueden llevar a que la réplica sea muy deficiente. A continuación se exponen algunos casos. Algunos conjuntos de parámetros para algunos kernels tienen una muy baja tasa de aciertos (revise la línea “mínimo” en cada kernel). Con el kernel sigmoide puede llegar a tener tasas de acierto cercanas a cero, tanto en el conjunto de datos de entrenamiento como en el conjunto de datos de validación. Otros conjuntos de parámetros deficientes llevan a que con algunos SVR que obtienen errores de sobreestimación de réplica bastante grandes (>50%). Incluso, el mayor indicador de asimetría se ha obtenido con un kernel polinomial de grado 2 (1,95). No obstante, estos conjuntos de parámetros se presentan sólo para graficar que la elección de los valores de los parámetros no es una tarea trivial, sino que al contrario, es una tarea muy relevante para replicar el rating.

Tabla 44. Parámetros usados para encontrar la réplica más eficiente con un kernel radial y M2 de acuerdo a las tasas de acierto total.

C	g=0,01	g=0,08	g=0,25	g=0,33	g=0,55	g=0,75	g=0,9
0,005	29,87891	30,15506	30,12665	30,29345	29,49674	29,94468	30,20552
0,001	31,33146	28,46365	29,19064	30,5279	30,15114	30,24554	29,20086
0,05	42,32713	45,79932	40,26172	40,3415	38,72391	38,876	38,01595
0,01	29,03945	38,24028	37,561	39,01455	31,40894	29,30162	30,28142
0,5	50,07692	53,91899	50,41734	51,91895	48,56165	44,34584	44,92766
0,1	45,90866	46,60401	42,91714	43,23951	38,28867	41,33747	41,48735
1	47,67342	50,09248	52,06584	53,16754	51,14116	52,78701	50,25341
5	53,25164	55,88436	56,34615	53,68575	50,58499	51,24144	51,62887
10	51,30308	52,64949	55,24452	53,71666	50,8016	52,90862	48,26241
15	49,65073	56,18856	54,19718	53,81802	51,87033	53,15578	50,14005

Para encontrar las mejores tasas de acierto considerando el problema de sobreentrenamiento, se han buscado rangos muy específicos de valores de los parámetros para hacer más eficientemente la réplica. En la Tabla 44 se muestra una plantilla de tasas porcentuales de acierto de acuerdo a los parámetros gamma y C. Las zonas de menor tonalidad indican las tasas de acierto más elevadas. La Figura 28 incluye gráficas de los puntos óptimos de la combinación de parámetros para los kernel gaussiano y sigmoide. En el kernel radial (izquierda), la mayor tasa de acierto se obtiene cuando $g=0,25$ y $C=5$.

Figura 28. Gráfica las tasas de acierto con kernel radial y sigmoide



Nota: La gráfica de la izquierda se ha construido con tasas de acierto al usar el kernel radial y una zona mucho más acotada de valores de gamma y que coinciden con la Tabla 42. En la grafica de la derecha se ha usado un kernel sigmoide para graficar las tasas de acierto (en la ordenada). En la abscisa del costo la escala se encuentra cambiada inversamente, donde la cercanía a cero indica que el valor real es 100.

En resumen, en esta tarea de calibración de los parámetros de los SVR una generalidad es que para lograr un mayor nivel de aciertos el coeficiente r tiene que ser igual a cero o tender a cero. Además, no hay razones para preferir que el valor de C sea más bien pequeño, y en algunos casos, como mucho igual a 100 (ver los mejores conjuntos de parámetros en la Tabla 42). Respecto a los valores de γ , las mejores tasas de acierto se logran cuando es cercano a 0, o al menos, menores a 1. El vínculo que hay entre C y γ es muy fuerte, de tal manera que si se pretende replicar con mayores tasas de acierto, si el valor de C es grande (aunque menor que 100), el valor de γ debería ser muy pequeño (cercano a cero).

Comparando el desempeño de los distintos kernel en el proceso de calibración puede generalizarse lo siguiente:

- a) La calibración con el kernel lineal es el más inestable de todos, porque el valor que debería tomar C para maximizar las tasas de acierto depende mucho del conjunto de datos sobre los cuales entrene. En cambio, las restantes funciones núcleo son bastante estables, ya que los conjuntos de parámetros óptimos con los cuales se obtienen las mejores tasas de acierto son relativamente similares y no dependen tanto del conjunto de datos que tiene para entrenar.
- b) Los kernels con mayores problemas de sobreentrenamiento son el polinomial de grado 2 y el radial. Si se observa la Tabla 42 se puede ver como con ambos kernels se logran tasas de acierto del 100% en el conjunto de datos de entrenamiento. Sin embargo, al usar dichos SVR en el conjunto de datos de validación las tasas de acierto son mucho más bajas que el 100%. No obstante lo anterior, al usar otros conjuntos de parámetros, tanto el kernel radial como el polinomial de grado 2 logran muy buenos desempeños, descartando el problema de sobreentrenamiento.
- c) De aquellos conjuntos de parámetros con los cuales se logran las mejores tasas de acierto (ver Tabla 43) la asimetría obtenida con los kernels no es mayor a la lograda con AD y regresión logística. En algunas oportunidades, la asimetría con SVR es nula.
- d) Para replicar el rating con el kernel polinomial de grado 3 el coste computacional es prohibitivamente alto. Por ello, la calibración no pudo llevarse a cabo.

5.2.2.2 Resultados de la réplica de rating con 7 clases

Luego de haber calibrado los parámetros de los SVR usados para obtener el mayor grado de aciertos en la réplica de rating, se ha conseguido un conjunto óptimo de parámetros que se expone en la Tabla 45.

Tabla 45. Parámetros que hacen la réplica de rating con mayores niveles de acierto.

Kernel con M1	r	gamma	C
Lineal	-	-	0,00001
Polinomial G1	-0,00001	2	1
Polinomial G2	0	2	0,001
Radial	-	0,01	10
Sigmoide	0	0,0001	100
Kernel con M2	r	gamma	C
Lineal	-	-	10
Polinomial G1	0	1	0,1
Polinomial G2	0	1	0,1
Radial	-	0,1	15
Sigmoide	0	0,0001	100

Con estos parámetros de los kernels se replicaron 30 veces los rating. Por una parte se tienen los estadísticos medios calculados con validación cruzada 10-cv dentro del conjunto de datos de entrenamiento y, por otra, se obtuvieron los estadísticos promedio calculados sobre el conjunto de validación que no se uso para entrenar los SVR. Un resumen de dichos resultados se encuentra en la Tabla 46. En esta tabla se observa que para M1 en la validación cruzada el menor error (0,3765) fue el logrado por el kernel radial, que a su vez logró el menor error subestimado y sobrestimado calculado sobre los datos de la matriz de confusión (6,2% en ambos casos). Además, en este caso la asimetría fue relativamente nula. La réplica con este kernel superó por mucho a las réplicas logradas con AD y con regresión logística. La tasa de aciertos en la clase de rating llegó al 87,5%, es decir, un 34,3% superior a la lograda con AD y un 29,5% superior a la lograda con regresión logística. Además, el tiempo demorado en realizar el entrenamiento fue uno de los más bajos (15,4 segundos), a excepción del obtenido por AD (0,2 segundos). El kernel que le sigue en eficiencia es el polinomial de grado 2 con 3,1% de diferencia en la tasa de acierto y con un mayor grado de sobrestimación del rating.

Por otra parte, si son tomados en cuenta los estadísticos de error, acierto y simetría que fueron calculados fuera de la muestra de entrenamiento, el kernel radial continúa siendo el más eficiente ya que logra el menor error cuadrático medio (0,6668) y el mayor porcentaje de aciertos sobre las clases reales de rating (61,5%). Con este kernel también se han obtenido los menores errores de sobrestimación (18,8%). La réplica lograda con esta función núcleo aventajan en un 13,7% a los resultados con AD y en un 8,2% a los resultados con regresión logística. El otro kernel que obtuvo satisfactorios niveles de acierto ha sido el sigmoidial, con un 60,2% de acierto total y la segunda mejor tasa de error de sobrestimación (19,4%).

Tabla 46. Resumen de resultados de las mejores réplicas con diferentes técnicas

Estadísticos calculados en la muestra de entrenamiento con M1

	RMSE	acierto (%)	Error sobrest.(%)	Error subest.(%)	tiempo (seg.)	Simetría Total
Lineal	0,6117	60,9804	20,3362	18,6834	42,81	1,0885
Polinomial G1	0,6254	61,3221	19,4699	19,2080	77,08	1,0136
Polinomial G2	0,4312	84,4278	7,1330	8,4392	18,16	0,8452
Radial	0,3765	87,5289	6,2355	6,2356	15,35	1,0000
Sigmoide	0,6377	61,1389	19,6570	19,2042	14,07	1,0236
AD	0,8343	53,2549	22,3907	24,3544	0,20	0,9194
Reg.Logíst.Ord.	0,8980	58,0297	18,1351	23,8352	51,97	0,7609

Estadísticos calculados sobre datos fuera de la muestra con M1

	RMSE	acierto (%)	Error sobrest.(%)	Error subest.(%)	Simetría Total
Lineal	0,6711	59,0782	22,0134	18,9084	1,16
Polinomial G1	0,6681	59,6435	20,2087	20,1478	1,00
Polinomial G2	1,2962	55,0731	20,9599	23,9669	0,87
Radial	0,6668	61,5180	18,7738	19,7082	0,95
Sigmoide	0,6413	60,1909	19,3671	20,4420	0,95
AD	0,8659	47,8171	22,3933	29,7896	0,75
Reg.Logíst.Ord.	0,9270	53,3386	21,1762	25,4852	0,83

Estadísticos calculados en la muestra de entrenamiento con M2

	RMSE	acierto (%)	Error sobrest.(%)	Error subest.(%)	tiempo (seg.)	Simetría Total
Lineal	0,8333	48,7620	24,7124	26,5256	4,69	0,9316
Polinomial G1	0,8442	48,0023	24,8537	27,1440	2,84	0,9156
Polinomial G2	1,0194	40,8492	32,7255	26,4253	7,69	1,2384
Radial	0,5073	75,7619	12,7139	11,5242	7,16	1,1032
Sigmoide	0,8453	46,7887	27,0640	26,1473	4,85	1,0351
AD	0,8986	49,8898	23,1701	26,9401	0,12	0,8601
Reg.Logíst.Ord.	0,8015	52,9438	23,5504	23,5058	0,58	1,0019

Estadísticos calculados sobre datos fuera de la muestra con M2

	RMSE	acierto (%)	Error sobrest.(%)	Error subest.(%)	Simetría Total
Lineal	0,8777	48,0978	25,3823	26,5199	0,96
Polinomial G1	0,8425	48,9427	25,3616	25,6957	0,99
Polinomial G2	1,6486	37,8686	33,2850	28,8464	1,15
Radial	0,7744	59,2953	22,3852	18,3195	1,22
Sigmoide	0,8531	49,6947	26,2825	24,0228	1,09
AD	0,9606	47,7426	23,7007	28,5567	0,83
Reg.Logíst.Ord.	0,7979	52,3491	23,3490	24,3020	0,96

Desde la Tabla 46 se puede observar que la mejor técnica en replicar rating, tanto en M1 como en M2, es la SVR con kernel radial, aunque es seguida por los resultados obtenidos con el kernel sigmoide y por la regresión logística. Se puede revisar en la Tabla A 73 del Anexo E todas las diferencias calculadas entre las tasas de acierto obtenidas para las técnicas usadas. Cuando se evalúan los estadísticos en el conjunto de datos de validación y todas las variables, la eficiencia de la SVR radial supera en 6,95% a la regresión logística y en 11,55% al AD cuando se usa M2. La diferencia entre las tasas de acierto obtenidas con SVR radial y regresión logística es significativa al 5% de error, medido con test de Levene (igual 11,4 y p-value de 0,1%) o con el test de Mann-Whitney (Wilcoxon-W = 466,000, Z = -6,640, p-value = 0,0). Todas las restantes diferencias de las tasas de acierto logradas con las otras técnicas, respecto de las obtenidas con SVR radial, son mayores y, por lo tanto, significativas. El desempeño de los restantes kernel cuando se usa M2 es similar al obtenido por AD, aun cuando el desempeño del kernel sigmoide (con aciertos del 49,7%) es bastante bueno.

Por otra parte, un aspecto que resalta bastante es que en la mayoría de los indicadores del error de nivel 1 de las técnicas estadísticas son mayores los errores de subestimación que de sobrestimación (ver Tabla 47). Esto no ocurre en los indicadores de error de los SVM, lo que también se puede deducir de los indicadores de simetría de nivel 1. Por otra parte, en la mayoría de los errores de sobrestimación de los niveles 2 y 3 son mayores que los de subestimación, tanto si son resultado de la réplica con técnicas estadísticas como si son SVM. Por ese mismo hecho, la asimetría total en la mayoría de las técnicas usadas estaba cercana a 1, al producirse una compensación entre las asimetrías de niveles 1, 2, 3 y 4.

Tabla 47. Estadísticos de error de sobre y subestimación en la réplica, y su simetría.

	Tasas de error en la muestra de entrenamiento con M1								Simetría en la muestra con M1			
	sobre_1	sobre_2	sobre_3	sobre_4	sub_1	sub_2	sub_3	sub_4	Sim N1	Sim N2	Sim N3	Sim N4
Lineal	19,0915	1,1473	0,0974	0	17,7089	0,9745	0	0	1,0781	1,1773	-	-
Polinomial G1	17,7698	1,4782	0,2220	0	18,4267	0,7813	0	0	0,9643	1,8920	-	-
Polinomial G2	6,3371	0,5672	0,2287	0	8,0434	0,3958	0	0	0,7879	1,4330	-	-
Radial	5,7497	0,3120	0,1738	0	5,7809	0,4547	0	0	0,9946	0,6862	-	-
Sigmoide	18,2802	1,1637	0,2132	0	18,0983	1,1059	0	0	1,0100	1,0523	-	-
AD	18,8837	2,8569	0,6236	0,0265	21,3825	2,9719	0	0	0,8831	0,9613	-	-
Reg.Logíst.Ord.	15,9758	1,8804	0,1704	0,1084	21,4808	2,0074	0,3284	0,0186	0,7437	0,9367	0,5189	5,8333
	Tasas de error sobre datos fuera de la muestra con M1								Simetría en la muestra con M1			
	sobre_1	sobre_2	sobre_3	sobre_4	sub_1	sub_2	sub_3	sub_4	Sim N1	Sim N2	Sim N3	Sim N4
Lineal	20,2822	1,3398	0,3914	0	18,1767	0,7318	0	0	1,1158	1,8308	-	-
Polinomial G1	18,9581	1,1481	0,1025	0	18,6097	1,5380	0	0	1,0187	0,7465	-	-
Polinomial G2	17,2918	2,8296	0,8386	0	18,9259	3,8780	0,6289	0,5341	0,9137	0,7296	1,3335	-
Radial	16,8332	1,7679	0,1727	0	18,0318	1,6764	0	0	0,9335	1,0546	-	-
Sigmoide	17,8718	1,3726	0,1227	0	19,5202	0,9218	0	0	0,9156	1,4891	-	-
AD	18,7732	3,1958	0,3518	0,0725	26,6865	3,0928	0,0103	0	0,7035	1,0333	34,0872	-
Reg.Logíst.Ord.	17,4758	3,2360	0,2814	0,1830	23,4968	1,6122	0,3520	0,0242	0,7438	2,0072	0,7995	7,5576
	Tasas de error en la muestra de entrenamiento con M2								Simetría fuera de la muestra con M2			
	sobre_1	sobre_2	sobre_3	sobre_4	sub_1	sub_2	sub_3	sub_4	Sim N1	Sim N2	Sim N3	Sim N4
Lineal	20,9401	3,3832	0,3892	0	24,6329	1,8928	0	0	0,8501	1,787	-	-
Polinomial G1	21,0634	3,4288	0,3616	0	25,0680	2,0760	0	0	0,8402	1,652	-	-
Polinomial G2	24,1265	7,5879	0,9055	0,1055	20,8511	5,0291	0,5451	0	1,1571	1,509	1,6612	-
Radial	11,5287	1,0790	0,1061	0	10,9803	0,5440	0	0	1,0500	1,984	-	-
Sigmoide	22,3856	4,2065	0,4719	0	24,1384	2,0088	0	0	0,9274	2,094	-	-
AD	18,3990	3,9511	0,8200	0	22,9760	3,8966	0,0675	0	0,8008	1,014	12,14246	-
Reg.Logíst.Ord.	19,8439	3,4295	0,2726	0,0045	21,9545	1,5513	0	0	0,9039	2,211	-	-
	Tasas de error sobre datos fuera de la muestra con M2								Simetría en la muestra con M2			
	sobre_1	sobre_2	sobre_3	sobre_4	sub_1	sub_2	sub_3	sub_4	Sim N1	Sim N2	Sim N3	Sim N4
Lineal	21,0591	3,7439	0,5793	0	24,5444	1,9755	0	0	0,8580	1,8952	-	-
Polinomial G1	20,1593	4,4128	0,7894	0	24,0968	1,5990	0	0	0,8366	2,7598	-	-
Polinomial G2	23,5394	7,5847	1,1958	0,9651	21,7558	6,7759	0,3147	0	1,0820	1,1194	3,799	-
Radial	20,0579	1,9135	0,4138	0	14,9989	3,0102	0,3104	0	1,3373	0,6357	1,333	-
Sigmoide	21,0482	4,7956	0,4388	0	21,8192	2,2036	0	0	0,9647	2,1763	-	-
AD	18,1366	3,8481	1,5477	0,16830	24,0237	4,5329	0	0	0,7549	0,8489	-	-
Reg.Logíst.Ord.	19,6448	3,5325	0,1717	0,0000	22,9385	1,3635	0	0	0,8564	2,5908	-	-

También resulta interesante observar que las réplicas con M1 logradas con regresión logística y con el kernel polinomial 2 causan errores de subestimación de nivel 4. En la evaluación de errores de sobrestimación de nivel 4, además de las técnicas antes mencionadas, las replicas con AD también causan problemas de clasificación. En general, este tipo de error es muy costoso para los inversionistas, sobre todo el error de sobrestimación.

Otro aspecto que se ha tomado en cuenta para medir la eficiencia de las técnicas de réplica de rating ha sido el coste computacional. En este caso ha sido medido en función del tiempo que ha demorado la técnica en encontrar la solución final para realizar la réplica. En la Tabla 48 se expone el tiempo en segundos de cuánto es lo que ha demorado en promedio cada técnica en realizar el entrenamiento o ajuste, según corresponda. En general, esta tarea se ha logrado en mucho menos tiempo cuando se utiliza M2 en vez de M1. También se puede decir de esta tabla que, por lo general, los SVR demoran más tiempo en entrenar los datos que lo que demoran las técnicas estadísticas en realizar los ajustes y estimaciones paramétricas. La excepción, en este caso, es la regresión logística ordinal, ya que para encontrar la solución óptima para una matriz de 32 variables y 7 segmentos de rating se tuvo que utilizar un algoritmo de optimización más extenso y costoso en términos computacionales. Esta desventaja de los SVR por sobre las técnicas estadísticas cada día queda más relegada debido a la potencia de los ordenadores. No obstante, en la misma tabla se expone un ejemplo basado en la cantidad de sistemas automáticos que se usaron para esta tesis (aproximadamente unas 5.500 en total). De esta manera se puede dimensionar más fácilmente la demora que causa la elección entre diferentes SVR. Para este ejemplo, se corrieron los SVR en un AMD Sempron 3000+ de 1,8 Ghz.

Tabla 48. Demora media en entrenamiento.

Técnica	Demora (segundos)		Tiempo usado en tesis	
	M1	M2	M1	M2
Lineal	42,81	4,69	2h 43m	17m 53s
Polinomial G1	77,08	2,84	14h 43m	32m 30s
Polinomial G2	18,16	7,69	3h 28m	88m 7s
Radial	15,35	7,16	1h 57m	54m 43s
Sigmoide	14,07	4,85	2h 41m	55m 32s
AD	0,20	0,12		
Reg.Logíst.Ord.	51,97	0,58		

Cabe destacar que todos los resultados de acierto, error y asimetría que se han obtenido con los modelos estadísticos padecen de algunos problemas asociados con sus supuestos. Uno de ellos es el de la multicolinealidad. Cuando se ha usado M2 la multicolinealidad es baja, debido a la forma en que se han seleccionado las variables; en cambio, hay evidencias de multicolinealidad cuando se ha usado M1 (ver Anexo D). El efecto de la multicolinealidad exagerada causa un mayor incremento en los errores estándar y disminuye la robustez de los coeficientes aplicados para la réplica (Hair et al., 1999). Esta es una clara ventaja del uso de M2 frente a M1.

Otro de los problemas asociados a las técnicas estadísticas está en que no se cumplen algunos supuestos distribucionales. Para usar AD un importante requisito es que se cumpla la normalidad multivariante de los datos que ayudan a replicar el rating. Esto no sucede con muchas de las variables usadas en esta tesis (ver punto 0 en el anexo). De la evaluación de los residuos de la aplicación de las regresiones logísticas se verifica que tampoco no cumple con el supuesto de distribución binomial.

También se evidencian problemas en el uso AD en la fase 2 debido a que el tamaño de los grupos resulta muy pequeño para el uso de M1. Concretamente, suele recomendarse que si no existe equilibrio entre los grupos de datos (en este caso agrupados por clases de rating), al menos el número de datos de dichos grupos debe superar el número de variables con alguna holgura (Hair et al., 1999). Esto es lo que no sucede en la fase 2 cuando se usa M1, ya que los grupos de clases de rating AAA-AA, C y D tienen menos datos que variables.

En general, el incumplimiento de los supuestos en los modelos estadísticos merman la eficiencia de las réplicas y debilitan la generalización de los modelos para la aplicación de la réplica en otra muestra relativamente similar. Esta es una seria desventaja frente a los SVM utilizados en esta tesis.

En resumen, la mejor réplica de rating, medido según la tasa de aciertos, se logra con el kernel radial de los SVR, tanto si se trata de la etapa de entrenamiento como de la etapa de validación, o tanto si se usa M1 como si se usa M2. Luego, al comparar, en la etapa de entrenamiento, el desempeño obtenido entre los SVR y las técnicas estadísticas (AD y regresión logística), con el uso de M1, todas los SVR tienen mejor desempeño; en cambio con el uso de M2, sólo el kernel radial logra mejor desempeño que las técnicas estadísticas, aunque lo hace por mucha diferencia (26% sobre el logrado con AD y 23% sobre el obtenido con regresión logística).

Al comparar el desempeño, en la etapa de validación, el desempeño obtenido entre los SVR y las técnicas estadísticas (AD y regresión logística), con el uso de M1, nuevamente todos los SVR tienen mejor desempeño; en cambio con el uso de M2, sólo el kernel radial logra mejor desempeño que las técnicas estadísticas (12% sobre el logrado con AD y 7% sobre el obtenido con regresión logística), aunque el desempeño logrado con el kernel sigmoide es bastante bueno (50% de aciertos, que es un 2% superior al obtenido con AD y un 2% inferior obtenido con regresión logística). Los peores desempeños logrados con las técnicas estadísticas, frente a los SVR, se deben en parte al incumplimiento de los supuestos que dichas técnicas suponen. Los supuestos más vulnerados han sido los de AD, que es justamente la técnica que ha tenido las más bajas tasas de acierto. Esta es una fortaleza bastante importante de los SVR.

5.2.3 Mejoras potenciales de la mejor SVR con datos discretizados

En la fase 3 del trabajo de réplica de rating se ha utilizado la discretización de los datos de entrada como una alternativa que podría mejorar el nivel de aciertos. Para ello se ha utilizado el método de discretización supervisada CAIM (el mismo expuesto en el apartado 5.1.5). Luego de tener los datos discretizados, se han usado tres tipos de kernel con SVR: un radial, un lineal y un sigmoide. En todas las funciones núcleo se ha usado con M2. Se ha elegido el kernel radial debido a que ésta ha sido la

función núcleo que logró mayores niveles de aciertos. Mientras que el kernel lineal y sigmoide fueron aquellos con los cuales se obtuvo menor tasas de acierto.

Con el kernel radial y datos discretizados se ha usado los parámetros $\gamma=0,1$; $C=15$. Los niveles de desempeño de esta SVR se observan en la Tabla 49.

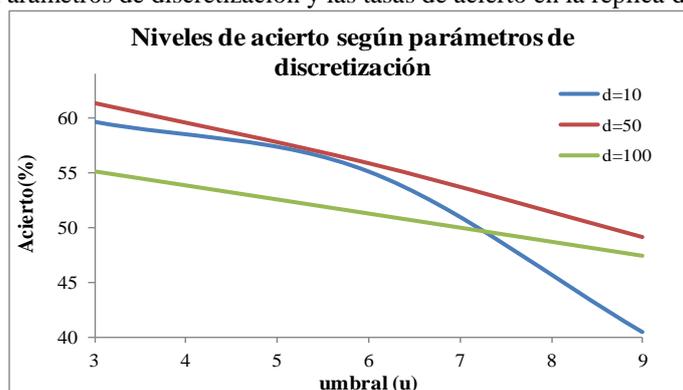
Tabla 49. Desempeño de la SVR con mejor desempeño M2 fuera de la muestra ($\gamma=0,1$; $C=15$)

delta	umbral de corte	Tiempo de entrenamiento	Tasas de acierto (%)	Tasas de error (%)		Simetría de errores		
				sobrestimadas	subestimadas	Simetría _T	Simetría _{N1}	Simetría _{N2}
10	0,3	7,54	59,61	18,68	21,70	0,86	0,80	1,17
10	0,6	7,10	55,09	22,79	22,12	1,03	0,96	1,61
10	0,9	4,46	40,46	29,70	29,84	1,00	0,89	1,50
50	0,3	7,65	61,34	23,95	14,71	1,63	1,60	1,89
50	0,6	6,06	55,84	21,26	22,90	0,93	0,90	1,16
50	0,9	4,94	49,09	26,02	24,89	1,05	1,15	0,53
100	0,3	7,38	55,13	22,96	21,91	1,05	1,08	0,48
100	0,6	5,41	51,28	25,01	23,70	1,06	1,02	1,23
100	0,9	4,18	47,42	26,22	26,36	0,99	1,00	0,85
SVR sin discretizar		7,16	61,52	18,77	19,71	0,95	0,93	1,05

Nota: los valores ennegrecidos son los más relevantes en la tabla. El tiempo de entrenamiento está expresado en segundos.

En esta tabla se aprecian las tasas de acierto, de error de sobrestimación y subestimación y los coeficientes de simetría de los errores frente al cambio de valores de los dos parámetros del proceso de discretización: delta y el umbral de corte. También se presentan los resultados con datos sin discretizar. Siguiendo a Ruiz (2006), en la mayoría de los casos en que se ha usado una técnica de discretización, ésta ha significado una pérdida de información, que se sacrifica por la simplificación producida y por la mayor facilidad en la interpretación de los resultados. En cambio, en este caso, con el adecuado ajuste en los parámetros de discretización no se ha perdido información, manteniendo los niveles de predicción. Concretamente, si el umbral de corte es 0,3 y delta es 10 ó 50, las tasas de acierto son similares a las obtenidas con los datos no discretizados. No obstante, el error de sobrestimación obtenido con el proceso de discretización es relativamente más elevado. En la Tabla 49 esto se ve reflejado también en los indicadores de simetría total, del nivel 1 y de nivel 2. Por lo tanto, lo que resulta relevante en este caso, es encontrar los parámetros adecuados de discretización. Tal como se evidencia en la Figura 29, los niveles de acierto disminuyen en la medida que el valor del umbral crece.

Figura 29. Parámetros de discretización y las tasas de acierto en la réplica de la Tabla 49.



Las otras dos funciones núcleo que también se han usado en este experimento de discretización de variables son la lineal y la sigmoide. Se han elegido estas dos funciones debido a que tuvieron los más pobres resultados en igual medida en la fase 2. Con ambos kernels, y con datos discretizados, las tasas de acierto no han disminuciones significativas. Incluso, cuando se ha usado el kernel lineal se ha ganado 3,5% en la tasa de acierto de la réplica de los datos de validación. Al contrario, cuando se ha usado el kernel sigmoide se ha perdido un 1,1% en la misma. No obstante, estas variaciones no representan variaciones estadísticamente significativas (al 5% de error, sobre la base de 30 iteraciones). La Tabla 50 muestra los estadísticos que se han obtenido en la réplica sobre los datos de validación con y sin procesos de discretización.

Tabla 50. Mejores desempeños para cada kernel usando datos diferentes tipos de datos de origen.

Kernel	datos discretizados	Tasas de acierto (%)	Tasas de error (%)		Simetría de errores		
			sobrestim.	subestimad.	Simetría _T	Simetría _{N1}	Simetría _{N2}
Radial	no	61,52	18,77	19,71	0,95	0,93	1,05
	si	61,34	23,95	14,71	1,63	1,60	1,89
Lineal	no	48,10	25,38	26,52	0,86	1,90	-
	si	51,62	22,64	25,74	0,88	0,76	1,75
Sigmoide	no	49,69	26,28	24,02	0,96	2,18	-
	si	48,55	26,11	25,34	0,91	2,57	-

En resumen, la adecuada discretización de variables no lleva a peor réplica de rating, incluso si se trata de un kernel lineal, la tasa de aciertos aumenta levemente (3,5%). Encontrar los valores de los parámetros, delta y umbral de corte, en el proceso de discretización no es irrelevante, ya que la elección errónea de ellos puede llevar a bajísimas tasas de acierto (ver Tabla 49). Por otra parte, elegir bajos valores de los parámetros (para conseguir mayor número de intervalos) tampoco disminuye las tasas de error, sino que el conjunto óptimo de parámetros se encuentra cuando $\delta = 50$ y $\text{umbral} = 0,3$.

Capítulo 6. Conclusiones y futuras investigaciones

En el presente capítulo se exponen las conclusiones de esta tesis y las posibles líneas a seguir en el futuro. Los resultados obtenidos se han logrado luego de revisar diversas investigaciones acerca de la réplica de rating y de medición de riesgo crediticio. También se han revisado las diferentes técnicas y metodologías empleadas para la réplica de rating, relacionadas con el uso de las variables que ayudan a la réplica, el diseño de los experimentos, la medición de la bondad de la réplica y la elección de la técnica clasificatoria. En relación a los objetivos propuestos, las conclusiones se pueden resumir genéricamente en los siguientes puntos:

1. En la muestra seleccionada ha sido posible replicar el rating corporativo con algunas técnicas de inteligencia artificial, con una granularidad de 2 y de 7 clases, obteniéndose los resultados deseados, ya que el grado de acierto de la predicción ha sido satisfactorio. En concreto, al utilizar los Sistemas Automáticos de Soporte Vectorial, tanto clasificatorios como regresivos, se pueden replicar los ratings crediticios de una manera eficiente y sin vulnerar supuestos asociados a la técnica. La eficiencia queda justificada como sigue:
 - En el caso de las réplicas con SVM biclasificatorios las tasas de acierto obtenidas, previa calibración de los parámetros, siempre resultaron ser mayores a las logradas con análisis discriminante. Estas tasas de acierto obtenidas con SVM resultaron ser similares a las logradas con regresión logística.
 - Al utilizar los SVM regresivos, previa calibración, y todas las variables de la muestra todos los kernels permiten replicar el rating con mayor eficiencia que con las técnicas estadísticas convencionalmente usadas en la literatura revisada en esta tesis. Esta eficiencia se ha evaluado en función de las tasas de acierto, las tasas de errores y la simetría de éstas. Al usar un conjunto más reducido de variables, los resultados obtenidos con la mayoría de los kernels es más eficiente que aquellos logrados con análisis discriminante, y sólo los resultados obtenidos con el kernel radial siempre son más eficientes en la tarea de replicar que aquellos obtenidos con regresión logística.
 - Una vez realizada la calibración de parámetros, los kernels que permiten mejores desempeños en la réplica de rating, fuera de la muestra, son el radial y el sigmoide, logrando que las mayores tasas de acierto para 7 clases de rating sean del 61,5% y 60,2%. Estos niveles de eficiencia fueron mayores que los obtenidos con análisis discriminante (47,8%) y regresión logística (53,3%).

2. La-discretización de las variables con la metodología CAIM* no conlleva a una disminución en los resultados clasificatorios, incluso los mejora cuando se usa el kernel lineal. Las tasas de acierto logradas con los kernels radial y sigmoide no variaron significativamente con los datos discretizados, a pesar de que en la literatura revisada se advierte que se suele perder poder de predicción al usar variables discretizadas. Esto abre una nueva línea de investigación.

A continuación se describen estas conclusiones con mayor detalle.

6.1 Metodología utilizada para la réplica del rating

En el capítulo 2 y 3 se expone la revisión de cómo en la bibliografía se ha abordado el problema de la medición del riesgo crediticio y de la réplica del rating en particular. Concretamente, se han elegido variables financieras que rescatan características de las empresas y que se refieren a su tamaño, su nivel de actividades, su estructura de financiación y liquidez, su rentabilidad y la volatilidad que tienen sus acciones bursátiles. La exhibición de las características de estas variables se expone en el capítulo 4. La elección de todos los criterios se ha adoptado con la intención de que se puedan generalizar los resultados en otras muestras de datos relativamente similares.

Para esta tesis se ha elegido replicar el rating que S&P ha emitido sobre la calidad crediticia de compañías productivas, comerciales y de servicios que no pertenezcan al sector financiero ni de seguros, debido a la homogeneidad que éstas presentan. Se han replicado rating de largo plazo en moneda local para concentrar la atención en el riesgo crediticio exclusivamente. La elección de datos de sólo un momento temporal (año 2002) también ayuda a la generalización de la réplica ya ésta no está perturbada por la autocorrelación temporal de rating.

La revisión de artículos muestra que la réplica puede llevarse a cabo con diferentes granularidades; pero la atención se concentra en un número de clases de rating que permita la diferenciación de la calidad de riesgo crediticio sin que importe mucho la granularidad máxima. Por ello, en esta tesis se ha preferido replicar el rating en 2 y en 7 clases, que permita la generalización fuera de la muestra de datos. Con ello se ha obtenido una distribución de rating similar a la normal.

Respecto al diseño experimental, la separación de la muestra en dos conjuntos de datos para el entrenamiento (con validación cruzada 10-cv) y la validación, permite la comparación con las técnicas estadísticas y permite que los indicadores de bondad de la predicción sean lo más insesgado posibles. Respecto de los últimos, se han usado indicadores de acierto, error y simetría ya que son fáciles de comprender, permiten medir claramente la eficiencia en la predicción y son consistentes entre ellos.

6.2 Réplica del rating con SVM

Diversas investigaciones donde se usan técnicas estadísticas para replicar rating ven vulnerados los supuestos sobre los cuales son necesarios para utilizar adecuadamente estas técnicas (Lando, 2004; Koh, Tan y Goh, 2006). Con los datos de esta tesis también se muestra que no se cumplen algunos supuestos necesarios para usar análisis discriminante y regresión logística.

Los SVM no necesitan de supuestos acerca de los datos. Aun más, los efectos negativos en las técnicas estadísticas generados por valores extremos son minimizados con los SVM, debido a la importancia relativa que estos puntos tienen en los algoritmos de optimización.

Es conocido que los SVM tienen un robusto soporte y justificación estadística desde la Teoría del Aprendizaje Estadístico, que le permite minimizar el error de generalización y el error estructural. En esta tesis se ha comprobado que, con el debido ajuste de sus parámetros, la réplica fuera del conjunto de datos de entrenamiento es de mejor calidad que la de las técnicas estadísticas.

En esta tesis se ha expuesto que con la mayoría de los kernels usados se puede realizar la réplica de rating, obteniéndose una alta precisión. Al evaluar las tasas de acierto con validación cruzada 10-cv en el conjunto de datos de entrenamiento en la tarea de biclasificación con los SVM, con todos los kernels tuvieron mejor desempeño que los logrados con análisis discriminante, y el 94% de los kernels tuvo similar grado de desempeño que los logrados con regresión logística. Por otra parte, de la misma comparación realizada en la tarea de multclasificación realizada con SVR y técnicas estadísticas se obtienen similares conclusiones acerca de la gran fortaleza lograda con los kernels de estos sistemas automatizados.

Para esta tarea de réplica del rating con 7 clases se optó por el uso de SVR frente a SVM clasificatoria, debido al mejor desempeño logrado y que los SVR incluyen en su diseño la idea de la ordinalidad que se observa en los rating de las agencias crediticias. En términos de resultados, con los SVR se puede replicar el rating con mayor nivel de acierto que si ésta tarea es realizada con análisis discriminante y con regresión logística (ver Tabla 51). Cuando se realiza la comparación de los resultados con los datos de entrenamiento (basado en 10-cv), la diferencia es aún mayor que cuando se hace dicha comparación con datos que se han dejado para la validación. Cada uno de estos indicadores es el resultado de 30 iteraciones, segmentando los datos de una manera estratificada y aleatoria.

Tabla 51. Tasas de acierto (%) en la réplica de rating con las técnicas usadas y sus mejores parámetros.

	Datos de entrenamiento		Datos de validación		Simetría total en validación	
	M1	M2	M1	M2	M1	M2
SVR radial	87,5	75,8	61,5	59,3	0,9525	1,2219
R.Logística	58,0	52,9	53,3	52,3	0,8309	0,9607
A.Discriminante	53,3	49,9	47,8	47,7	0,7517	0,8299

En general, la diferencia entre las tasas de acierto obtenidas en la réplica con la SVR y el AD es significativa. También es significativa la diferencia que hay entre las tasas de acierto obtenidas con SVR radial y regresión logística. Además, hay evidencias de que el uso de SVR de un modelo predictivo (fuera de la muestra de entrenamiento) con más variables (M1) tiene ventajas frente a un modelo menos extensivo (M2), ya que estos sistemas automáticos permiten capturar toda la información disponible desde las variables explicativas, sin perder poder predictivo por la colinealidad que exista entre las variables. Este posiblemente sea el mismo motivo por el que al usar análisis discriminante la tasa de acierto no varíe significativamente al usar ambos conjuntos de variables (M1 y M2).

6.3 La elección del kernel y la calibración de sus parámetros

Una ventaja de los SVM es su modularidad, es decir, es que en la medida que se haga una elección apropiada de la función núcleo, la SVM puede adecuarse más a la resolución de un problema específico. En esta tesis se han usado cuatro tipos genéricos de funciones núcleo para evaluar cuál de ellos se adecúa de mejor forma a la réplica de rating.

En general, el kernel radial ha presentado mejores tasas de acierto en la réplica de rating. El otro kernel con el que se obtienen buenas tasas de acierto es el sigmoide. El kernel polinomial de grado 2 permite replicar con buenas tasas de acierto en la etapa de entrenamiento, pero al replicar dicho sistema automático con datos fuera del conjunto de entrenamiento la tasa de errores aumenta más de lo esperado (ver Tabla 46). Los resultados de réplica con el kernel lineal son los más inestables y los menos eficientes.

De los resultados de la tarea de calibración de los parámetros de los SVR se concluye que para obtener las mejores tasas de aciertos el coeficiente r debe tener un valor cercano a cero y γ un valor pequeño (cercano a 1). En muchos casos analizados, para lograr las menores tasas de error el factor de regularización o coste debe ser pequeño (ver Tabla 42). También se observó que el vínculo que hay entre C y γ es muy fuerte, de tal manera que si se pretende replicar con mayores tasas de acierto, si el valor de C es grande (aunque menor que 100), el valor de γ debe ser muy pequeño (cercano a cero), y viceversa. Los valores que permiten obtener el menor error con el conjunto de datos de validación para cada kernel se encuentra en la Tabla 45.

Con todo lo anterior se puede deducir que la tarea de aprendizaje realizada por los kernels resulta muy eficiente. En la mayoría de los kernels, el aprendizaje realizado en los datos de entrenamiento tiene tasas muy elevadas, incluso en los kernels radial y polinomial de grado 2 este proceso es tan eficiente que se obtienen tasas de error del 0% en la validación cruzada 10-cv (ver Tabla 43). Sin embargo, esto no quiere decir que la réplica fuera de la muestra de entrenamiento sea tan exitosa como para que no se

obtenían errores de clasificación. Diversos conjuntos de parámetros para estos dos kernels permiten tasas de acierto del 100% (ver Tabla 42), pero cuya réplica fuera de la muestra desciende drásticamente, incluso a veces baja al 45% (para 7 clases de rating). Por ello, es necesario que se haga previamente una calibración de los parámetros, para evitar el sobreentrenamiento. Este es la única tarea que requiere el uso de SVM, ya que no requiere cumplir ningún requisito adicional, más que la muestra sea la adecuada.

6.4 La discretización de variables es una tarea inconsciente que hacen los análisis financieros

Bajo la suposición de que, para emitir la opinión técnica del rating de las compañías, los expertos financieros inconscientemente evalúan las características de las empresas de una forma intervalar, se ha usado la técnica de discretización supervisada CAIM* para categorizar las variables que en esta tesis ayudan a replicar el rating.

En general, el uso de discretizaciones en un modelo predictivo supone una pérdida de información y del poder explicativo de las variables. En cambio los resultados obtenidos en la tarea de réplica con datos discretizados muestran que la discretización no provoca una caída en las tasas de acierto, e incluso incrementa levemente los niveles de acierto en la SVR con kernel lineal.

Por último, cabe destacar que los datos discretizados no se han podido usar en las técnicas estadísticas y sólo han sido empleados en los SVR, debido a la posibilidad y versatilidad que este tipo de técnica de Inteligencia Artificial permite.

6.5 Investigaciones futuras

Una línea de investigación futura es ampliar la réplica de rating con los SVR de tal manera que se logre replicar con toda la gama de categorías (22 clases: AAA, AA+, AA, AA-, BBB+, ... , D). Esto supone un siguiente paso en la línea de desarrollar sistemas automáticos para la emisión de rating tal y como lo hacen las agencias de rating.

En esta tesis se ha asumido que la distancia entre las clases de los valores del rating es la misma (en una escala de 1 a 7). Una futura investigación sería evaluar de qué otra manera o sobre la base de qué criterio se puede asignar valores a los rating de tal manera que se capture la diferencia de distancias entre las distintas clases.

Debido a la versatilidad de los SVM en un futuro se puede realizar la réplica de rating tras utilizar una función núcleo que permita el ingreso de variables con datos intervalares. Esta es una particularidad de los SVM, que permiten crear diversas arquitecturas de aprendizaje con bastante versatilidad.

Respecto del trabajo de discretización de datos, una interesante línea sería estudiar el efecto de la división de los datos de acuerdo a patrones con el país o el sector industrial al que pertenece la compañía sobre la cual se emite el rating. Junto con esto es importante ampliar la base de datos de tal manera de que todos subgrupos tengan suficientes datos para el entrenamiento.

La ampliación de datos de rating a períodos posteriores ayudaría a diferentes focos de atención. Uno de ellos sería el estudio de la variabilidad de los rating a través del tiempo y cómo ésta influye en posteriores calificaciones crediticias.

Referencias

- Adya, M. & Collopy, F. (1998). How Effective are Neural Networks at Forecasting and Prediction? A Review and Evaluation. Journal of Forecasting, 17, 481-495.
- Ahn, H. & Kim, K-J. (2011). Corporate Credit Rating using Multiclass Classification Models with order Information. WASET 2011 World Academy Of Science, Engineering and Technology, 60, 95-100.
- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. Journal of Finance, 23 (4), 589-609.
- Altman, E.I. (2002). Revisiting Credit Scoring Models in a Basel 2 Environment, disponible en Ong, M. (2002). Credit Rating: Methodologies, Rationale and Default Risk, London Risk Books.
- Altman, E.I., Haldeman, R. & Narayanan, P. (1977). ZETA Analysis: A New Model to Identify Bankruptcy Risk of Corporations, Journal of Banking and Finance, June, 29-54.
- Altman, E.I. & Saunders, A. (1998), Credit Risk Measurement: Developments Over the Last 20 Years, Journal of Banking and Finance, 21, 1721-1742.
- Ammann, M. (2001). Credit Risk Valuation: Methods, Models and Applications, 2da. Ed.: Springer-Verlag Berlin Heidelberg, Springer Finance.
- Andersson, P. (2001). Expertise in Credit Granting: Studies on Judgment and Decision-Making Behavior. Estocolmo, Suecia: Stockholm School of Economics.
- Angulo, C. (2001). Aprendizaje con máquinas núcleo en entornos de multclasificación. Barcelona, Cataluña: Universitat Politècnica de Catalunya, Departament d'Enginyeria de Sistemes, Automàtica i Informàtica Industrial, Tesis doctoral. Tesis doctoral.
- Angulo, C. & Català, A. (2001). Ordinal Regression with K-SVCR Machines. IWANN '01 Proceedings of the 6th International Work-Conference on Artificial and Natural Neural Networks: Connectionist Models of Neurons, Learning Processes and Artificial Intelligence-Part I, Springer-Verlag.
- Argenti, J. (1977), Company Failure – Long Range Prediction is Not Enough, Accountancy, Agosto.
- Arvanitis, A. & Gregory, J. (2001). Credit: The Complete Guide to Pricing, Hedging and Risk Management, London, GB.: Risk Books, p. 424.
- Back, B., Laitinen, T., Sere, K. & van Wezel, M. (1996). Choosing Bankruptcy Predictors Using Discriminant Analysis, Logit Analysis, and Genetic Algorithms. Turku Centre for Computer Science, Finlandia, Technical Report N° 40, Septiembre.
- Baesens, B., Van Gestel, T., Viaene, S., Stepanova, M., Suykens, J. & Vanthienen, J. (2003). Benchmarking State of the Art Classification Algorithms for Credit Scoring. Journal of the Operational Research Society, 54, 627–635.
- Baetge, J., Muss, M. & Niehaus, H. (1988). The use of statistical analysis to identify the financial strength of corporations in Germany. Studies in Banking and Finance, 7, 183-196.
- Balcaen, S & Ooghe, H. (2004). Alternative methodologies in studies on business failure: do they produce better results than the classical statistical methods?. Universitet Gent, Bélgica. Working Paper 249.
- Bank for International Settlements, BIS (1988). Basel Capital Accord. Comité de Supervisión Bancaria de Basilea, <http://www.bis.org/publ/bcbs04a.htm>, descargado la página web el 31 de julio de 2002.
- Bank for International Settlements, BIS (2003). New Basel Capital Accord. Comité de Supervisión Bancaria de Basilea. Abril, <http://www.bis.org/publ/bcbsca.htm>, descargado la página web el 18 de mayo de 2004.

- Bank for International Settlements, BIS (2004). International Convergence of Capital Measurement and Capital Standards: a Revised Framework (Marco Revisado), Basilea, Suiza, junio, bajado el 15 de octubre de 2004 desde <http://www.bis.org/publ/bcbs107.htm>.
- Bank for International Settlements, BIS (2009). Consultative proposals to strengthen the resilience of the banking sector announced by the Basel Committee, Bank of International Settlements. Descargado el 22 de marzo de 2012 desde <http://www.bis.org/press/p091217.htm>.
- Bank for International Settlements, BIS (2010). Basel III: International framework for liquidity risk measurement, standards and monitoring. Descargado el 12 de enero de 2012 desde <http://www.bis.org/publ/bcbs188.pdf>.
- Bank for International Settlements, BIS (2011). Basel III: A global regulatory framework for more resilient banks and banking systems. Descargado el 12 de enero de 2012 desde <http://www.bis.org/publ/bcbs189.pdf>.
- Barnes, P. (1987). The Analysis and use of Financial Ratios: A Review Article. Journal of Business Finance and Accounting, 14 (4), 449-461.
- Battese, G.E. & Coelli, T.J. (1995). A model for technical inefficiency effects in a stochastic frontier production function for panel data. Empirical Economics, 20 (2), 325-332, doi : 10.1007/BF01205442.
- Beaver, W. H. (1966). Financial Ratios As Predictors of Failure. Journal of Accounting Research, Supplement 5 (Empirical Research in Accounting: Selected Studies), 71-111.
- Becchetti, L. & Sierra, J. (2003). Bankruptcy risk and productive efficiency in manufacturing firms, Journal of Banking & Finance, 27 (11), 2099-2120.
- Belkin, M. (2003). Problems of Learning on Manifolds. Disertación doctoral, University of Chicago, Department of Mathematics, descargada el 13 de diciembre de 2010 desde <http://www.cse.ohio-state.edu/~mbelkin/papers/papers.html#thesis>.
- Bellotti, T. & Crook, J. (2009). Support vector machines for credit scoring and discovery of significant features. Expert Systems with Applications, 36 (2), 3302–3308, doi: 10.1016/j.eswa.2008.01.005.
- Bellotti, T., Matousek, R. & Stewart, C. (2011a). Are rating agencies' assignments opaque? Evidence from international banks. Expert Systems with Applications, 38 (4), 4206–4214, doi: 10.1016/j.eswa.2010.09.085.
- Bellotti, T., Matousek, R. & Stewart, C. (2011b). A note comparing support vector machines and ordered choice models' predictions of international banks' ratings. Decision Support Systems, 51 (3), 682–687, doi: 10.1016/j.dss.2011.03.008.
- Bennett, K.P. & Campbell, C. (2000). Support Vector Machines: Hype or Hallelyjah? SIGKDD Explorations, 2 (2), 1-8.
- Berenji, H. R. and Khedkar, P. (1992). Learning and Tuning Fuzzy Logic Controllers Through Reinforcements. IEEE Transactions on Neural Networks, 3, 724-740.
- Bessis, J. (2002). Risk Management in Banking. John Wiley & Sons, Ltd. Inglaterra: West Sussex.
- Bielecki, T.R. & Rutkowski, M. (2002). Credit Risk: Modeling, Valuation and Hedging. Berlin, Alemania: Springer-Verlag Berlin Heidelberg, Springer Finance.
- Black, F. & Cox, J. (1976). Valuing Corporate Securities: Some Effects of Bond Indenture Provisions, Journal of Finance, 31, 351-367.
- Blochwitz, S. & Eigermann, J. (1999). Effiziente Kreditrisikobeurteilung durch Diskriminanzanalyse mit qualitativen Merkmalen, disponible en Eller, R., Gruber, W. & Reif, M. (2000). Handbuch Kreditrisikomodelle und Kreditderivate, editorial Schäffer–Poeschel Verlag Stuttgart.
- Bloechlinger, A., Leippold, M. & Maire, B. (2012). Are Ratings the Worst Form of Credit Assessment Apart from All the Others? Swiss Finance Institute. Research Paper N°12-09. Descargado el 12 de marzo de 2012

desde <http://ssrn.com/abstract=2012277>.

- Blum, M. (1974). Failing Company Discriminant Analysis. Journal of Accounting Research, (Spring), 1-15.
- Boser, B.E., Guyon I.M. & Vapnik V.N. (1992). A training algorithm for optimal margin classifiers. En Haussler D. (ed.). Proceedings de Annual Conference on Computational Learning Theory. Pittsburgh, EE.UU: ACM Press, 144–152.
- Bouckaert, J. & Verboven, F. (2004). Price Squeezes in a Regulatory Environment. Journal of Regulatory Economics, 26 (3), 321-351.
- Bradford, J.P. & Brodley, C.E. (2001). The Effects of Instance-Space Partition in Significance. Machine Learning, 42 (3), 269-286.
- Breiman, L., Friedman, J.H., Olshen, R.A. & Stone, C.J. (1984). Classification and regression trees, Wadsworth, Belmont, EUA: Ed. Chapman and Hall/CRC.
- Brodley, C.E. & Utgoff, P.E. (1995). Multivariate Decision Trees. Machine Learning, 19, 45-77.
- Brown, C.E. & O'Leary, D.E. (1995). Introduction to artificial intelligence and expert systems. American Accounting Association, Sección AI/ES, bajada el 9 de septiembre de 2003 desde www.rutgers.edu/accounting/raw/aaa/aiet/aithome.html.
- Buhmann, M. (2003). Radial Basis Functions: Theory and Implementations. Cambridge, MA, EUA: Ed. Cambridge University.
- Bundtine, W. (1992). Learning Classification Tree. Statistics and Computing, 2, 63-73.
- Burgstahler D. & Dichev I. (1997). Earnings Management to Avoid Earnings Decreases and Losses. Journal of Accounting and Economics, 24 (1), 99-126.
- Byoun, S. & Shin, Y.S. (2012). Information Content of Unsolicited Credit Ratings: Evidence from Japanese Firms. Asia-Pacific Journal of Financial Studies. 41, 59–86 doi:10.1111/j.2041-6156.2011.01062.x
- Campos, R., Ruiz, F.J., Agell, N. & Angulo, C. (2004). Financial credit risk measurement prediction using innovative soft-computing techniques, Computational Finance & Its Applications, WIT Press, 57-66.
- Canals, J. (1997). Universal Banking: International Comparisons and Theoretical Perspectives. Oxford University Press, New York.
- Candel, D. (2011). Algoritmo tipo SMO para la AD-SVM Aplicado a Clasificación Multicategoría. Tesis. Universidad Técnica Federico Santa María, descargada el día 26 de febrero de 2012 desde www.alumnos.inf.utfsm.cl/~dcontard/tesis.pdf.
- Cao, L. (2002). Support vector machines experts for time series forecasting. Neurocomputing, 51, 321-339.
- Caouette, J.B., Altman, E.I. & Narayanan, P. (1998) Managing Credit Risk: The next great financial challenge. USA. & Canada: John Wiley & Sons, Inc., 452 p.
- Carey, M. & Hrycay, M. (2001). Parameterizing Credit Risk Models with Rating Data.
- Carty, L.V. (1997). Moody's Rating Migration and Credit Quality Correlation, 1920-1996, Moody's Investors Service, Inc., Moody's Special Comment, New York, EUA, Report N° 25097, Julio, bajado el 19 de mayo de 2004 desde www.moody.com, 25 pág.
- Casey C. & Bartczak N. (1984). Cash flow: It's not the Bottom Line. Harvard Business Review, 4, 60-66.
- Casilda, R., Lamothe, P. & Monjas, M. (1996). La banca y los mercados financieros. Madrid, España: Alianza Editorial.
- Catlett, J. (1991). On changing continuous attributes into ordered discrete attributes. EWSL '91, Proceedings of

the European Working Session on Machine Learning, 164–178, 1991.

- Chabanel, P. (2011). Implementing Basel III: Challenges, Options & Opportunities. Descargado el 15 de abril de 2012 desde <http://www.moodysanalytics.com/~media/Insight/Regulatory/Basel-III/Thought-Leadership/2011/11-01-09-Implementing-Basel-III-Whitepaper.ashx>.
- Chan, K., Lee, T-W., Sample, P.A., Goldbaum, M.H., Weinreb, R.N. & Sejnowski, T.J. (2002). Comparison of Machine Learning and Traditional Classifiers in Glaucoma Diagnosis. IEEE Transactions on Biomedical Engineering, 49 (9), 963-974.
- Chaveesuk, R., Srivaree-Ratana, C. & Smith, A.E. (1999). Alternative neural network approaches to corporate bond rating. Journal of Engineering Valuation and Cost Analysis, 2 (2), 117- 131.
- Chen, G. & Wei, Q. (2002). Fuzzy association rules and the extended mining algorithms. Information Sciences, 147 (1-4), 201-228, doi: 10.1016/S0020-0255(02)00264-5.
- Ching, J.Y., Wong, A.K.C. & Chan, K.C.C. (1995). Class-Dependent Discretization for Inductive Learning from Continuous and Mixed Mode Data, IEEE Transactions on Pattern Analysis and Machine Intelligence, 17 (7), 641-651.
- Cho, S-B, & Won, H-H. (2003). Machine Learning in DNA Microarray Analysis for Cancer Classification. First Asia-Pacific Bioinformatics Conference, Adelaide, Australia. Conferences in Research and Practice in Information Technology, 19. En Yi-Ping, Phoebe & Chen (Ed.). Coats, P. K. & Fant, L. F. (1992). A neural network approach to forecasting financial distress. The Journal of Business Forecasting, Winter, 9-12.
- Choi, S. (2009). The Effect of Outliers on Regression Analysis: Regime Type and Foreign Direct Investment. Quarterly Journal of Political Science, 4 (2), 153–165. <http://dx.doi.org/10.1561/100.00008021>.
- Colander, D., Follmer, H., Haas, A., Goldberg, M., Juselius, K., Kirman, A., Lux, T. & Sloth, B. (2009). The financial crisis and the systematic failure of economics. Kiel working paper. Kiel Institute for the World Economy. Kiel, Germany.
- Collett, N. & Schell, C. (1992). Corporate Credit Analysis. Londres, GB.: Euromoney Books PLC.
- Cortes, C. & Vapnik, V.N. (1995). Support vector networks. Machine Learning 20, 273- 297.
- Couderc, F. & Renault, O. (2004). Times-to-Default Life Cycle, Global and Industry Cycle Impacts, International Center for Financial Asset Management and Engineering (FAME), Research Paper N° 42, bajado desde <http://www.fame.ch> el 21 de diciembre de 2004.
- Coyle, B. (2000) Measuring Credit Risk. New York, USA: Glenlake Publishing Company, Ltd. & American Management Association (AMACOM).
- Crammer, K. & Singer, Y. (2001). On the algorithmic implementation of multiclass kernel-based vector machines. Journal of Machine Learning Research, (2):265-292.
- Credit Suisse Financial Products (1997). CrediRisk+: A Credit Management Framework. Credit Suisse Financial Products. Bajado desde <http://www.csfb.com/creditrisk>.
- Cristianini, N. & Shawe-Taylor, J. (2000). An Introduction to Support Vector Machines. Cambridge - New York: EUA: Cambridge University Press.
- Crosbie, P. J. (1999): Modeling Default Risk. KMV Publications. [http:// www.mkmv.com](http://www.mkmv.com).
- Dacunha-Castelle, D. & Florens-Zmirou, D. (1986). Estimation of the coefficients of a diffusion from discrete observations. Stochastics, 19 (4), 263-284, doi: 10.1080/17442508608833428.
- Danenas, P., Garsva, G. & Guda, S. (2011). Credit Risk Evaluation Model Development Using Support Vector Based Classifiers. Procedia Computer Science, 4, 1699–1707.
- Deakin, E.F. (1972). A Discriminant Analysis of Predictors of Business Failure, Journal of Accounting

Research, Spring, 167 – 179.

- Declaración del G20. (2008). Declaration of the Summit on Financial Markets and the World Economy. Office of the Press Secretary, 15 de noviembre de 2008. Descargado el 15 de abril de 2012 desde <http://georgewbush-whitehouse.archives.gov/news/releases/2008/11/20081115-1.html>.
- del Águila Q., J., Cortés G., F.J., Fernández R., I. & García M., F.J. (2002). El Riesgo en la Industria Bancaria: Una aproximación a Basilea II; Almería, España: Caja Rural Intermediterránea, Cajamar.
- Delianedis, G. & Geske, R. (2001). The Components of Corporate Risk Spreads. Working Paper. Anderson School. UCLA, bajado el 28 de noviembre de 2003 desde www.anderson.ucla.edu.
- Desai, V.S., Crook, J.N. & Overstreet, G.A. (1996). A comparison of neural networks and linear scoring models in the credit union environment. *European Journal of Operational Research*, 95 (1), 24-37.
- Dhumale, R. (1998). Earnings Retention as a Specification Mechanism in Logistic Bankruptcy Models: A Test of the Free Cash Flow Theory. *Journal of Business Finance & Accounting*, 25 (7), 1005-1023.
- Diamantidis, N.A., Karlis, D., Giakoumakis, E.A. (2000). Unsupervised stratification of cross-validation for accuracy estimation. *Artificial Intelligence*, 116, 1-16.
- Dougherty, J., Kohavi, R. & Sahami, M. (1995). Supervised and unsupervised discretization of continuous features ; en *Proceedings of the Twelfth International Conference on Machine Learning*. Los Altos, CA: Morgan Kaufmann.
- Drucker, H., Burges, C.J.C., Kaufman, L., Smola, A.J. & Vapnik, V.N. (1997). Support Vector Regression Machines, en *Advances in Neural Information Processing Systems 9*, NIPS 1996, 155–161, MIT Press.
- Duffie, D. & Lando, D. (2001). Term Structures of Credit Spreads with Incomplete Accounting Information, *Econometrica*, 69, 633-64.
- Durand, D. (1941). Risk Elements in Consumer Instalment Financing. National Bureau of Economic Research.
- Dutta, S. & Shekhar, S. (1988). Bond rating: a non-conservative application of neural networks. *Proceedings of IEEE International Conference on Neural Networks*, II443-II450.
- Dwyer, D.W., Kocagil, A.E. & Stein, R.M. (2004). The Moody's KMV EDF™ RiskCalc™ V3.1 Model. Moody's KMV Company, credo el 5 de Abril, bajado el 22 de octubre de 2004 desde www.moodykmv.com.
- Edelstein, R.H. (1975). Improving the Selection of Credit Risks: An Analysis of a Commercial Bank Minority Lending Program. *Journal of Finance*, 30, 37-55.
- Edminster, R.O. (1972). An Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction, *Journal of Financial and Quantitative Analysis*, March, 1477-1493.
- El Karoui, N. & Martellini, L. (2002). A Theoretical Inspection of the Market Price for Default Risk, October, Working paper, Marshall School of Business, University of Southern California.
- English, W.B. & Nelson, W.R. (1998). Credit Risk Rating of Business Loans. Finance and Economics Discussion Series, Federal Reserve Board, 47 págs., [bajado el 26 de marzo de 2003 desde]
- Escolano, F., Cazorla, M.A., Alfonso, M.I., Colomina, O. & Lozano, M.A. (2003). Inteligencia Artificial. Modelos, Técnicas y Áreas de Aplicación. Madrid, España: Thomson Editores España.
- Esterhuysen, J., van Vuuren, G. & Styger, P. (2011). The Effect of Stressed Economic Conditions on Credit Risk in Basel II. *South African Journal of Economic and Management Sciences*, 14 (2), 122-137.
- Everett, J. & Watson, J. (1998). Small business failures and external risk factors. *Small Business Economics*, 11 (4), 371-390.

- Ewert, D.C. (1969). Trade Credit Manager: Selection of Accounts Receivable Using a Statistical Model. Krannert Graduate School of Industrial Administration, Working Paper N° 236, Perdue University.
- Fan, R., Chen, P. & Lin, Ch. (2005). Working Set Selection Using Second Order Information for Training Support Vector Machines. *Journal of Machine Learning Research*, 6, 1889–1918.
- Fan, A. P. & Palaniswami, M. (2000). Selecting bankruptcy predictors using a support vector machine approach. *Proceedings of IEEE-INNS-ENNS International Joint Conference on Neural Networks, IJCNN 2000*, 6, 354–359.
- Fayyad, U.M. (1994). Branching on Attribute Values Tree Decisión. 12th. National Conference on Artificial Intelligence AAAI-94, Proceedings, 601-606.
- Fayyad, U., & Irani, K. (1993). Multi-interval discretization of continuous-value attributes for classification learning, en *Proceedings of the Thirteenth International Joint Conference on Artificial Intelligence*. San Mateo, CA: Morgan Kaufmann.
- Fernández R. & Viennet, E. (1999) Face identification using support vector machines. *European Symposium on Artificial Neural Networks - ESANN99, Proceedings*, 195-200.
- Financial Times Stock Exchange, FTSE (2003). FTSE Global Classification System. Versión 2.1, enero, bajado desde http://www.ftse.com/.indices_marketdata/global_classification/overview.jsp el día 06 de septiembre de 2005.
- Firth, M., & Poon, W. (2005). Are unsolicited ratings lower? Preliminary evidence from Fitch's bank individual ratings. *Journal of Business Finance & Accounting*, 32, 1741–1771.
- Fisher R.A., (1936) The use of multiple measurements in taxonomic problems, *Annals of Eugenics* 7, 179-188.
- Fitzpatrick, P. (1932). A comparison of the ratios of successful industrial enterprises with those of failed companies. The Accountants Publishing Company.
- Flagg, J.C. & Giroux, G.A. (1991). Predicting corporate bankruptcy using failing firms. *Review of Financial Economics*; 1(1), 67-78.
- Fletcher, D. & Goss, E. (1993). Forecasting with neural networks: an application using bankruptcy data. *Information & Management*, 24, 159-167.
- Fogel, D. (1988). An evolutionary approach to the traveling salesman problem. *Biological Cybernetics*, 60 (2), 139-144.
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80, 185–201.
- Forrest, S. (1993). Genetic algorithms: principles of natural selection applied to computation. *Science*, 261, .872-878.
- Fosler, G. (2011). Credit Default Swaps and the Financial System: An Interview with Marti Subrahmanyam. Entrevista a Marti Subrahmanyam realizada el 18 de diciembre de 2011. Descargado el 15 de abril de 2012 desde <http://www.gailfosler.com/featured/credit-default-swaps-and-the-financial-system-an-interview-with-marti-subrahmanyam>.
- Freimann, E. (1998). Economic Integration and Country Allocation in Europe. *Financial Analysts Journal*. 54 (5), 32-41.
- Frerichsa, H. & Wahrenburga, M. (2003). Evaluating internal credit rating systems depending on bank size. Working Paper Series Finance and Accounting (University of Frankfurt), 115, Septiembre.
- Freund, Y. & Schapire, R. (1997). A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting, *Journal of Computer and System Sciences*, 55 (1), 119-139.

- Friedman, J.H. (1977). A recursive partitioning decision rule for non-parametric classification. IEEE Transactions on Computers, abril, 404-408.
- Frydman, H., Altman, E.I. & Kao, D.L. (1985). Introducing recursive partitioning for financial classification: the case of financial distress. Journal of Finance, 40 (1), 269-291.
- Galil, K. (2003). The Quality of Corporate Credit Rating: An Empirical Investigation. EFMA 2003, Helsinki Meetings. Descargado el 27 de mayo de 2005 desde <http://ssrn.com/abstract=406681>. Doi: <http://dx.doi.org/10.2139/ssrn.406681>.
- Galindo, J. & Tamayo, P. (2000). Credit Risk Assessment Using Statistical and Machine Learning: Basic Methodology and Risk Modeling Applications. Computational Economics, 15, 107-143.
- Garavaglia, S. (1991). An application of a counter-propagation neural network: simulating the Standard and Poor's Corporate Bond Rating system. Proceedings, First International Conference on Artificial Intelligence on Wall Street, 9 al 11 de Oct, 278 –287.
- Geisser, S. (1975). The Predictive Sample Reuse Method with Application. Journal of the American Statistical Association, 70, 320-328.
- Gentry J.A., Newbold P. & Whitford D.T. (1985). Predicting Bankruptcy: If Cash Flow's not the Bottom Line, What is?. Financial Analysts Journal, 41 (5), 47-56.
- Geske, R., (1977). The Valuation of Corporate Liabilities as Compound Options, Journal of Financial and Quantitative Analysis, 12, (4). 541-552.
- Giesecke, K. (2002). Correlated Default with Incomplete Information. Cornell University, Department of Operations Research and Industrial Engineering, EUA, Diciembre 20, a publicar en Journal of Banking and Finance.
- Giesecke, K. & Goldberg, L. (2004). Forecasting Default in the Face of Uncertainty. Journal of Derivatives, 12, 1, Mayo, 14-25.
- Glantz, M. (2003). Managing Bank Risk. An Introduction to Broad-Base Credit Engineering. San Diego, EUA: Academic Press, 668 p.
- Glasserman, P. & Li, J. (2004). Importance sampling for portfolio credit risk. Management Science, 51 (11), 1643-1656, doi: 10.1287/mnsc.1050.0415.
- Goldbaum, M.H., Sample, P.A., Chan, K., Williams, J., Lee, T-W., Blumenthal, E., Girkin, C.A., Zangwill, L., Bowd, C., Sejnowski, T.J. & Weinreb, R.N. (2002). Comparing Machine Learning Classifiers for Diagnosing Glaucoma from Standard Automated Perimetry. Investigative Ophthalmology & Visual Science, January 2002, 43,(1), 162-169.
- Goldberg, D. (2002), The Design of Innovation: Lessons from and for Competent Genetic Algorithms. Editorial Addison-Wesley, Reading, MA, EUA.
- Gonçalves, C., Rodrigues, M. & Soares, T. (2008). Correlation of Business Cycles in the Euro Zone. Working paper, Departamento Economía, Universidad de Sao Paulo.
- Grossberg, S. (1988). Neural Networks and Natural Intelligence, Cambridge, MA: The Mitt Press.
- Gupton, G., Finger, C. & Bhatia, M. (1997). CreditMetrics - Technical Document, J.P. Morgan & Co. Inc., bajado el 27 de octubre de 2003 desde <http://www.jpmorgan.com/RiskManagement/CreditMetrics>.
- Hair, J.F., Anderson, R.E., Tatham, R.L. & Black, W.C. (1999). Análisis Multivariante. Madrid, España: Prentice Hall Iberia, 5ta. ed.
- Haiss, P. & Sümegi, K. (2008). The relationship between insurance and economic growth in Europe: a theoretical and empirical analysis. Empirica, 35 (4), 405-431, Doi: 10.1007/s10663-008-9075-2

- Hale, J. y Sheno, S. (1996). Analyzing FD inference in relational databases. Data & Knowledge Engineering, 18 (2), 167-183, doi: 10.1016/0169-023X(95)00033-O.
- Hamilton, D.T., Gupton, G. & Berthault, A. (2001). Default and Recovery Rates of Corporate Bond Issuers: 2000. Moody's Investors Service, Inc., Moody's Special Comment, New York, EUA, Report Number 63770, febrero, bajado el 19 de mayo de 2004 desde www.moody.com.
- Hammer, M. (1983). Failure prediction: sensitivity of classification accuracy to alternative statistical methods and variable sets, Journal of Accounting and Public Policy, 2, 289-307.
- Han, I. & Jhee, W.C. (1993). Intelligent credit rating system. Pan Pacific Conference on Information Systems, Proceedings, 267-274.
- Härde, W., Moro, R.A. & Schäfer, D. (2004). Rating Companies with Support Vector Machines. DIW Berlin, German Institute for Economic Research, Discusión Paper N° 416, bajado desde www.diw.de el 17 de junio de 2005.
- Härde, W., Moro, R.A. & Schäfer, D. (2005). Predicting Bankruptcy with Support Vector Machines. SFB N° 649 Discussion Paper 2005-009, Deutsche Forschungsgemeinschaft.
- Härle, P., Lüders, E., Papanides, T., Pfetsch, S., Poppensieker, T. & Stegemann, U. (2010). Basel III and European banking: Its impact, how banks might respond, and the challenges of implementation. EMEA Banking, McKinsey & Company Paper. Descargado el 15 de febrero de 2012 desde http://www.mckinsey.com/~media/McKinsey/dotcom/client_service/Risk/Working_papers/26_Basel_III_and_European_banking.ashx.
- Hassan, M. & Kalhoefer, C. (2011). Regulation of Credit Rating Agencies. Evidence from Recent Crisis. Working Paper N° 26, Faculty of Management Technology, German University in Cairo. Disponible en http://econpapers.repec.org/scripts/redir.pf?u=http%3A%2F%2Fmgt.guc.edu.eg%2Fwpapers%2F026hassan_kalhoefer2011.pdf;h=repec:guc:wpaper:26.
- Hastie, T., Tibshirani, R. & Friedman, J. H. (2001). The elements of statistical learning: Data mining, inference, and prediction. Editorial Springer Verlag. New York, EUA.
- Haykin, S. (1999). Neural Networks: A Comprehensive Foundation. Editorial Prentice Hall, 2a. ed., Upper Saddle River, NJ, EUA.
- Heckman, J. (1979). Sample Selection Bias as a Specification Error. *Econometrica*, 47 (1), 153-161.
- Henley, W.E. & Hand, D.J. (1997). Construction of a k-nearest neighbour credit-scoring system. *IMA Journal of Mathematics Applied in Business and Industry*, 8, 305-321.
- Herbrich, R., Graepel, T., & Obermayer, K. (1999). Regression Models for Ordinal Data: A Machine Learning Approach, Reporte Técnico 99-3, Technical University of Berlin, descargado el 21 de noviembre de 2005 desde <http://w3.cs.tu-berlin.de/cs/ifb/TeBericht/99/tr99-3.ps>.
- Hernández, J., Ramírez, M.J. & Ferri, C. (2004). Introducción a la Minería de Datos. Madrid, España: Editorial Pearson Educación S.A.
- Hillegeist, S.A., Keating, E.K., Cram, D.P. & Lundstedt, K.G. (2004). Assessing the Probability of Bankruptcy, Review of Accounting Studies, 9(1), 5-34.
- Hilscher, J. & Wilson, M.I. (2012). Credit Ratings and Credit Risk. Disponible en Social Science Research Network, SSRN, <http://ssrn.com/abstract=1474863>, doi: 10.2139/ssrn.1474863
- Holland, J. (1992). Genetic algorithms. Scientific American, julio, 66-72.
- Horrigan, J.O. (1966). The determination of long term credit standing with financial ratios. Journal of Accounting Research, Suplemento, 44- 62.
- Hosmer, D. & Lemeshow, S. (2000). Applied Logistic Regression. New York, EUA: Editorial Wiley, 2ª edic.

- Hsu, Ch., Chang, Ch. & Lin, Ch. (2010). A Practical Guide to Support Vector Classification. Descargada el 30 de noviembre de 2011 desde <http://www.csie.ntu.edu.tw/~cjlin>.
- Huang, W., Nakamori, Y. & Wang, S-Y. (2005). Forecasting stock market movement direction with support vector machine. Computers & Operations Research, 32(10), 2513–2522, doi: 10.1016/j.cor.2004.03.016.
- Huang, Z., Chen, H., Hsu, Ch., Chen, W. & Wu, S. (2004). Credit rating Analysis with Support Vector Machines and Neural Networks: a Market Comparative Study. Decision Support System, 37 (4), 553-558.
- Huang, Ch., Chen, M. & Wang, Ch. (2007). Credit Card Scoring with a Data Mining Approach Based on Support Vector Machines. Expert Systems with Applications, 33, 847–856, doi:10.1016/j.eswa.2006.07.007.
- Hull, J. & White, A. (1995). The Impact of Default Risk on the Prices of Options and Other Derivative Securities, Journal of Banking and Finance, 19, 299-322.
- Hunt, E.B., Marin, J. & Stone, P.J. (1966). Experiments in induction. New York, EUA: Academic Press.
- Ivry, B. (2008). Paulson Seeks Mortgage Value That Eluded Bear, Lehman (Update1). Entrevista a Henry Paulson, secretario del U.S. Treasury, 24 de Septiembre de 2008, 13:31 EDT. Descargado el 10 de marzo de 2012 desde http://www.bloomberg.com/apps/news?pid=newsarchive&refer=home&sid=aGT_xTYzbbQE.
- Janikow, C.Z. (1998). Fuzzy Decision Trees: Issues and Methods. 1998 IEEE International Conference on Systems, Man, and Cybernetics, 28 (1), 1-14.
- Jantzen, J. (2007). Foundations of Fuzzy Control. Editorial Wiley.
- Jarrow, R. A. & Deventer, D.R. van. (2001). Practical Use of Credit Risk Models in Loan Portfolio and Counterparty Exposure Management, en Arvanitis y Gregory, (2001). Credit: The Complete Guide to Pricing, Hedging and Risk Management, London, GB.: Risk Books, 338-349.
- Jarrow, R. A., Lando, D. & Turnbull, S. (1997). A Markov Model for the Term Structure of Credit Spreads, Review of Financial Studies, 10 (Summer). 481-523.
- Jarrow, R. & Turnbull, S. (1995). Pricing Derivatives on Financial Securities Subject to Credit Risk, Journal of Finance, 50 (1), 53-85.
- Jilani, T. A. & Burney S. M.. (2008). Multiclass Bilateral-Weighted Fuzzy Support Vector Machine to Evaluate Financial Strength Credit Rating. ICCSIT '08, 2008 International Conference on Computer Science and Information Technology, agosto 29 – septiembre 2, 342 – 348, doi: 10.1109-ICCSIT.2008.191.
- Jeacle, I., O'Hogartaigh, C. & O'Hogartaigh, M. (2000). A Chronology of Calculation: Accounting, History and Accounting History, 8º Congreso Mundial de Historiadores de la Contabilidad, Madrid, España, 19 – 21 de Julio, Asociación Española de Contabilidad y Administración de Empresas (AECA).
- Joachims, T. (1999). Making Large-scale SVM Learning Practical. En Advances in Kernel Methods — Support Vector Learning. URL http://www-ai.cs.uni-dortmund.de/DOKUMENTE/joachims_99a.ps.gz.
- Joachims, T. (2008). SVMmulticlass: Multi-class Support Vector Machine. Descargado el 16 de marzo de 2012 desde http://svmlight.joachims.org/svm_multiclass.html.
- Joos P., Vanhoof, K., Ooghe H. & Sierens N. (1998). Credit classification: A comparison of logit models and decision trees. Workshop on Application of Machine Learning and Data Mining in Finance, 10th European Conference on Machine Learning, Proceedings, 24 de abril, Chemnitz Alemania, 59-72.
- Justino, E.J.R., Bortolozzi, F & Sabourin. R. (2005). A comparison od SVM and HMM classifiers in the off-line signature verification. Pattern Recognition Letters, 26 (9), 1377-1385.
- Kamaloo, E. & Abadeh, M.S. (2010). An artificial immune system for extracting fuzzy rules in credit scoring. Evolutionary Computation (CEC), 2010 IEEE Congress on. 1-8, Doi : 10.1109/CEC.2010.5586346.
- Kaplan, R. & Urwitz G. (1979). Statistical Models of Bond Ratings: A Methodological Inquiry. Journal of

Business, 52 (2), 231-261.

- Karatzoglou, A., Meyer, D. & Hornik, K. (2006). Support Vector Machines in R. *Journal of Statistical Software*, 15 (9), 1-28. <http://www.jstatsoft.org/v15/i09/>
- Kealhofer, S., Kwok, S. & Weng, W. (1998). Uses and Abuses of Bond Default Rates. California, EUA: KMV Co., Document Number: 999-0000-039. Originalmente publicado en J. P. Morgan CreditMetric's Monitor, 1er. cuatrimestre de 1998, bajado el 19 de mayo de 2004 desde www.kmv.com.
- Kearns, M. (1988). Thoughts on Hypothesis Boosting. Manuscrito.
- Kearns, M. & Mansour, Y. (1996). On the boosting ability of top-down decision tree learning algorithms. *Journal of Computer and Systems Sciences*, 58 (1), 109-128.
- Keasey, K. & Watson, R. (1987) Non-Financial Symptoms and the Prediction of Small Company Failure. *Journal of Business Finance & Accounting*; 14 (3), 335-354.
- Kim, J. W. Weistroffer, H. R. & Redmond, R. T. (1993). Expert systems for bond rating: A comparative analysis of statistical, rule-based and neural network systems. *Expert Systems*, 10 (3), 167-171, doi: 10.1111/j.1468-0394.1993.tb00093.x.
- Kingdon, J. & Feldman, K. (1995). Genetic Algorithms for Bankruptcy Prediction. Search Space Research Report N° 01-95, SearchSpace Ltd, Londres.
- Koh, H. (1992). The Sensitivity of Optimal Cutoff Points to Misclassification Costs of Type I and Type II Errors in the Going-Concern Prediction Context. *Journal of Business Finance & Accounting*, 19 (2), 187-197. DOI: 10.1111/j.1468-5957.1992.tb00618.x
- Koh, H., Tan, W. & Goh, C. (2006). A Two-step Method to Construct Credit Scoring Models with Data Mining Techniques. *International Journal of Business and Information*, 1(1), 96-118.
- Kohavi, R. (1995). A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. *International Joint Conference on Artificial Intelligence, IJCAI 1995*, doi=10.1.1.48.529.
- Kohonen, T. (1989). *Self-organization and Associative Memory*, (Springer-Verlag, Berlin).
- Kotsiantis, S. & Kanellopoulos, D. (2006). Discretization Techniques: A recent survey. *GESTS International Transactions on Computer Science and Engineering*, 32 (1), 47-58.
- Kou, G., Peng, Y, Shi, Y. & Chen, Z. (2006). A new multi-criteria convex quadratic programming model for credit analysis. *ICCS'06 Proceedings of the 6th international conference on Computational Science - Volume Part IV*, Springer-Verlag Berlin, Heidelberg, doi: 10.1007/11758549_67.
- Koza, J. (1992). *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. Cambridge, Massachussets, EUA: MIT Press.
- Krahn, J.P. & Weber, M. (2001). Generally Accepted Rating Principles: A Primer. *Journal of Banking and Finance*. 25 (1), January, 3-23.
- Kurgan, L. & Cios, K.J. (2001). Discretization Algorithm that Uses Class-Attribute Interdependence Maximization. *Proceedings de International Conference on Artificial Intelligence (ICAI-2001)*, Las Vegas, 980-987.
- Kwon, Y.S., Han, I. & Lee, K.C. (1997). Ordinal Pairwise Partitioning (OPP) Approach to Neural Networks Training in Bond Rating; *Intelligent Systems in Accounting, Finance and Management*, 6 (1), 23-40
- Lachenbruch, P.A. & Mickey, M.R. (1968). Estimation of Error Rates in Discriminant Analysis. *Technometrics*, 10, 1-11.
- Laitinen, T. & Kankaanpää, M. (1999). Comparative analysis of failure prediction methods: the Finnish case. *European Accounting Review*, 8 (1), 67-92.

- Lando, D. (2004). *Credit Risk Modelling. Theory and Applications*. Princeton University Press.
- Lee, Y. (2007). Application of support vector machines to corporate credit rating prediction. *Journal Expert Systems with Applications*, 33 (1), 67-74.
- Lee, D.H. & Kim, M.H. (1997). Database Summarization Using Fuzzy ISA Hierarchies. 1998 IEEE International Conference on Systems, Man, and Cybernetics Part B, 27 (1), 68-78.
- Lee, J. & Verleysen, M. (2007). *Nonlinear Dimensionality Reduction*. Serie Information Science and statistics, New York, EUA: Springer.
- Levin, C. & Coburn, T. (2011). *Wall Street and The Financial Crisis: Anatomy of a Financial Collapse*. Majority and minority staff report, Permanent Subcommittee on Investigations, Senado de EUA. Descargado desde http://www.hsgac.senate.gov/imo/media/doc/Financial_Crisis/FinancialCrisisReport.pdf?attempt=2 el 21 de enero de 2012.
- Lewis, M. (2011). *Boomerang. Touring the Ruins of the Old Economy*. W. W. Norton & Company.
- Lin, H-T. & Lin, C-J. (2003). A study on sigmoid kernels for SVM and the training of non-PSD kernels by SMO-type methods. Reporte técnico, National Taiwan University, Department of Computer Science, descargado el 3 de enero de 2005 desde <http://www.csie.ntu.edu.tw/~cjlin/papers/tanh.pdf>.
- Lincoln, M. (1982). An empirical study of the usefulness of accounting ratios to describe levels of insolvency risk. Ph.D. thesis, University of Melbourne. En Lincoln, M. (1984), *Journal of Banking & Finance*.
- Little, R. & Rubin, D. (1986). *Statistical analysis with missing data*. New York, NY, USA: John Wiley & Sons, Inc.
- Litterman, R. & Iben, T. (1991) Corporate Bond Valuation and the Term Structure of Credit Spreads”, *Financial Analysts Journal*, 17 (3), 52-64.
- Liu, C., Frazier, P. & Kumar, L. (2007). Comparative assessment of the measures of thematic classification accuracy. *Remote Sensing of Environment*, 107, 606–616.
- Liu, H., Hussain, F., Tan, C.L. & Dash, M. (2002). Discretization: An Enabling Technique. *Data Mining and Knowledge Discovery*, 6, 393 - 423.
- Loh, W-Y. & Shih, Y-S. (1997). Split selection methods for classification trees. *Statistica Sinica*, 7 (4), 815-840.
- Longstaff, F. A. & Schwartz, E. S. (1995). A Simple Approach to Valuing Risky Fixed and Floating Rate Debt., *Journal of Finance*, 50 (3), 789-819.
- López P., J. (1996). *El Rating y las Agencias de Calificación*. Madrid, España: Editorial DYKINSON S.L..
- Luengo, J., García, S. & Herrera, F. (2011). On the choice of the best imputation methods for missing values considering three groups of classification methods. *Knowledge and Information Systems*. 1-32, DOI: 10.1007/s10115-011-0424-2
- Maher, J.J. & Sen, T.K. (1997). Predicting bond ratings using neural networks: a comparison with logistic regression. *Intelligent Systems in Accounting, Finance and Management*, 6, 59– 72.
- Mählmann, T. (2004). *Classification of Rating of Firms in Presence of Financial and Non-financial Information*. University of Cologne Albertus-Magnus-Platz, Alemania, Working Paper, bajado el 27 de mayo de 2005 desde http://www.defaultrisk.com/pp_score_27.htm.
- Makowski P., (1985) Credit scoring branches out, *The Credit world*, 74 (2), 30-37.
- Maksimovic, V. & Phillips, G. (1998). Optimal Firm Size and the Growth of Conglomerate and Single-Industry Firms, Working Papers 98-14, Center for Economic Studies, U.S. Census Bureau. Descargado el 12 de diciembre de 2006 desde <ftp://ftp2.census.gov/ces/wp/1998/CES-WP-98-14.pdf>

- Malhotra, R. & Malhotra, D. K. (1999). Fuzzy Systems and Neuro-Computing in Credit Approval. Journal of Lending & Credit Risk Management, 81 (11), 24–27, (1999).
- Marczyk, A. (2004). Algoritmos genéticos y computación evolutiva. Bajado desde <http://the-geek.org/docs/algen/algen.html> el 20 de agosto de 2005.
- Marrison C. (2002). The Fundamentals of Risk Measurement. New York, EUA: McGraw-Hill.
- Martin, D. (1977). Early warning of bank failure: a logit regression approach. Journal of Banking Finance, 1 (3), 249-276.
- Martín del Brío, B. & Serrano, C. (1993). Self-Organizing Neural Networks for the Analysis and Representation of Data: Some Financial Cases. Neural Computing & Applications, Springer Verlag, 1, 193-206..
- Martínez A., R. (1999). El análisis multivariante en la investigación científica. Madrid, España: Editoriales La Muralla SA. y Hespérides, Cuadernos de Estadística.
- Mensah, Y.M. (1984). An examination of the Stationarity of Multivariate Bankruptcy Prediction Models: A methodology Study. Journal of Accounting Research, 22 (1), 380-395.
- Merriam Webster, Inc. (1997). Merriam - Webster's Collegiate Dictionary. 10a. ed. Massachusetts, EUA.: Merriam Webster, Incorporated, 1559.
- Merton, R. C. (1974). On the Pricing of Corporate Debt: The Risk Structure of Interest Rates, Journal of Finance, Junio, 29(2), 449-470.
- Meyer, D. (2011). Support Vector Machines. The Interface to libsvm in package e1071. Descargado el 12 de enero de 2012 desde <http://cran.r-project.org/web/packages/e1071/vignettes/svmdoc.pdf>.
- Meyer, D., Leisch, F., Hornik, K. (2003). The Support Vector Machine under Test. Neurocomputing, 55, 169–186.
- Michel, A.J. (1977). Municipal Bond Ratings: A Discriminant Analysis Approach. The Journal of Financial and Quantitative Analysis, 12(4), 587-598.
- Mitchell, M. (1996). An Introduction to Genetic Algorithms. MA., EUA: MIT Press.
- Modigliani, F. & Miller, M. (1958). The Cost of Capital, Corporation Finance and The Theory of Investment, American Economic Review, 48 (3), 267-297.
- Moody, J. & Darken, C. (1989). Fast learning in networks of locally tuned processing units. Neural Computation, 1, 281-294.
- Moody, J. & Utans, J. (1994). Architecture selection strategies for neural networks application to corporate bond rating. En Refenes, A. (ed.). Neural Networks in the Capital Markets, Wiley, Chi-chester, 277-300.
- Moody's Investors Service (1995). Global Credit Analysis. Londres, G.Bretaña: IRF Publishing Ltd., 2da. Reimpresión.
- Moore, D. & McCabe, G. (2005). Introduction to the practice of statistics. Editorial W.H. Freeman & Company, 5ª. edición.
- Moro, R. (2004). Rating Companies with Support Vector Machines. Berlín, Alemania: Humboldt-Universität zu Berlin, Center for Applied Statistics and Economics, Tesis de Master of Science.
- Myers, J. & Forgy, E. (1963). Development numerical Credit Evaluation Systems. Journal of the American Statistical Association, 58 (303), 799-806.
- Neophytou, E. & Mar, C. (2003). Predicting Corporate Failure in the UK: A Multidimensional Scaling Approach, Journal of Business, Finance and Accounting, forthcoming.

- Núñez, H. (2003). Sistemas híbridos con aprendizaje basados en máquinas de soporte vectorial y redes neuronales de función de base radial. Tesis doctoral, Universitat Politècnica de Catalunya.
- Ñanculef, R., Concha, C., Allende, H., Candel, D. & Moraga, C. (2009). AD-SVMs: A light extension of SVMs for multiclassification. *International Journal of Hybrid Intelligent Systems*, 6 (2), 69-79, doi 10.3233/HIS-2009-0087.
- Öğüt, H., Donağay, M., Ceylan, N. & Atkaş, R. (2012). Prediction of bank financial strength ratings: The case of Turkey. *Economic Modelling*, 29 (3), 632–640, doi : <http://dx.doi.org/10.1016/j.econmod.2012.01.010>.
- Ohlson, J.A. (1980) Financial ratios and the probabilistic prediction of bankruptcy, *Journal of Accounting Research*, 18(1), 109-131.
- Ong, M.K. (1999). *Internal Credit Risk Models: Capital Allocation and Performance Measurement*, London, GB.: Risk Books.
- Ooghe, H., Joos, P., & de Bourdeaudhuij, C. (1995). Financial Distress Models in Belgium: The Results of a Decade of Empirical Research. *International Journal of Accounting*, 30, 245-274.
- Orgler, Y.E. (1970) *Analytical methods in loan evaluation*. Massachusetts, EUA: Lexington Books, 109.
- Pacey, J. & Pham, T. (1990). The Predictiveness of Bankruptcy Models: Methodological Problems and Evidence, *Journal of Management*, 15 (2), 315-337.
- Pedrycz, W. (1996). Conditional Fuzzy C-Means, *Pattern Recognition Letters*, 17 (6), 625-632, doi: 10.1016/0167-8655(96)00027-X
- Pelckmans, K., De Brabanter, J., Suykens, J.A.K. & De Moor, B. (2005). Handling missing values in support vector machine classifiers. *Neural Networks*. 18, 684–692. doi:10.1016/j.neunet.2005.06.025.
- Peña, J.I. (2002). *La gestión de riesgos financieros de mercado y de crédito*. España: Pearson Educación SA. y Financial Times-Prentice, 121.
- Pinches, G. & Mingo, K. (1973). A multivariate analysis of industrial bond ratings. *Journal of Finance*. 28(1), 1-18.
- Piramuthu, S., (1999). Financial Credit Risk Evaluation with Neural and Neuro-Fuzzy Systems. *European Journal of Operational Research*, 112 (16), 310–321, doi: 10.1016/S0377-2217(97)00398-6.
- Platt, H.D. & Platt, M.B. (1990). Development of a class of stable predictive variables, *Journal of Business Finance & Accounting*, 17 (1), 31-51.
- Pogue, T.F., Soldofsky, R.M. (1969). What's in a bond rating?. *Journal of Financial and Quantitative Analysis*, 4 (2), 201- 228.
- Poon, W. (2003). Are unsolicited credit ratings biased downward? *Journal of Banking and Finance*, 27, 593–614.
- Pompe, P. & Bilderbeek, J. (2000). Faillissementspredictie: een vergelijking tussen lineaire discriminant analyse en neurale netwerken. *Economisch Sociaal Tijdschrift*, 2, 215-242.
- Press, S.J. & Wilson, S. (1978). Choosing Between Logistic Regression and Discriminant Analysis. *Journal of American Statistical Association*, Diciembre, 699-705.
- Prskawetz, A., Fent, T., Barthel, W., Crespo-Cuaresma, J., Lindh, T., Malmberg, B. & Halvarsson, M. (2007). The Relationship Between Demographic Change and Economic Growth in the EU. Research Report 32. Forschungsbericht Nro. 32. Institut für Demographie der Österreichischen Akademie der Wissenschaften.
- Quinlan, J.R. (1983). Learning efficient classification procedures, en *Machine learning: an Artificial Intelligence approach*. Palo Alto, EUA: Tioga Press.
- Quinlan, J.R. (1993): *C4.5: Programs for machine learning*. California, EUA: Morgan Kaufmann Publishers, Inc.

- R Development Core Team (2005). R: A Language and Environment for Statistical Computing. Reference Index. Disponible en <http://cran.r-project.org/doc/manuals/fullrefman.pdf>.
- Raiffa, H. & Schlaiffer, R. (1961). Applied Statistical Decision Theory, Massachusetts, EUA: Colonial Press.
- Raimbourg, P. (1990). Les Agencies de Rating, Paris, Francia: Gestion / Economica, Serie Polilique générale, Finance et Marketing.
- Rajan, U. Seru, A. & Vig, V. (2010). The Failure of Models That Predict Failure: Distance, Incentives and Defaults. Chicago GSB Research Paper N° 08-19, doi: 10.2139/ssrn.1296982.
- Ramser, J. & Foster, L. (1931). A demonstration of ratio analysis. University of Illinois, Bureau of Business Research, Urbana, EUA, Bulletin No. 40.
- Rast, M. (1997). Application of Fuzzy Neural Networks on Financial Problems. Annual Meeting of the North American Fuzzy Information Processing Society, NAFIPS '97, 21-24 Sept., 347-349.
- Ravi, V., Kurniawan, H., Thai, P. & Kumar, R. (2008). Soft computing system for bank performance prediction. Applied Soft Computing, 8(1), 305-315, doi : doi:10.1016/j.asoc.2007.02.001.
- Ripley, B., Kurt, H., Gebhardt, A. & Firth, D. (2012). Support Functions and Datasets for Venables and Ripley's MASS. Descargado el 14 de marzo de 2012 desde <http://www.stats.ox.ac.uk/pub/MASS4/>.
- Rösch, D. (2003). Correlations and Business Cycles of Credit Risk: Evidence from Bankruptcies in Germany. Department of Statistics, Faculty of Business and Economics, University of Regensburg, Germany, 6th Annual Meeting of the Swiss Society for Financial Market Research, 4 de abril, Zurich. bajado el 3 de Julio de 2003 desde <http://www.wiwi.uni-regensburg.de/hamerle/roesch/index.htm>.
- Rosenberg, E & Gleit, A. (1994). Quantitative Methods in Credit Management: A Survey. Operations Research, 42 (4), 589-613.
- Rosenblatt, F. (1962). Principles of Neurodynamics. New York, EUA: Spartan.
- Rovira, X., Agell, N., Sánchez, M., Prats, F. & Parra, X. (2004). An Approach to Qualitative Radial Basis Function Networks over Orders of Magnitude. 18° International Workshop on Qualitative Reasoning, NorthWestern U., Illinois, EUA
- Rovira, X., Ansoategui, C., Campos, R. & Sánchez, G. (2005). Predicción del Rating: Métodos Estadísticos Clásicos vs. Máquinas de Soporte Vectorial. Ponencia en Workshop sobre Inteligencia Computacional, CAEPIA 2005, Santiago de Compostela, 16 de noviembre de 2005.
- Ruiz, F.J. (2006) Funciones Núcleo en Sistemas Dinámicos con Información no Vectorial. Barcelona, Cataluña: Universitat Politècnica de Catalunya, Departament d'Enginyeria de Sistemes, Automàtica i Informàtica Industrial, Tesis doctoral.
- Ruiz, F.J., Angulo, C. & Agell, N. (2005). Discretización Supervisada para el Problema de Regresión. Séptimas Jornadas de Trabajo ARCA (JARCA'05). Málaga, España, 26 al 29 de Junio.
- Russell, S. & Norvig, P. (2003). Artificial Intelligence: A Modern Approach, Editorial Prentice Hall, 2a. ed.
- Saá-Requejo, J. & Santa Clara, P. (1997). Bond Pricing with Default Risk. Working Paper, J.E. Anderson Graduate School of Management, UCLA, 23.
- Salzberg, S. (1997). On Comparing Classifiers: Pitfalls to Avoid and a Recommended Approach. Data Mining and Knowledge Discovery, 1(3), 317-328, doi: 10.1023/A:1009752403260.
- Saunders, A. (1999). Credit risk measurement: new approaches to value risk and other paradigms, New York, USA.: John Wiley & Sons, Inc., 226.
- Schwefel, H-P. (1995). Evolution and Optimum Seeking. Wiley-Interscience.

- Serrano, C. (1996). Self Organizing Neural Networks for Financial Diagnosis. Decision Support Systems, 17 (Julio), 227-238.
- Shin, K.S. & Han, I. (2001). A case-based approach using inductive indexing for corporate bond rating. Decision Support Systems 32, 41–52.
- Simkovic, M. (2009). Secret Liens and the Financial Crisis of 2008. *American Bankruptcy Law Journal*, Vol. 83, 253- , descargado el 15 de marzo de 2012 desde SSRN: <http://ssrn.com/abstract=1323190>.
- Smola, A. & Schölkopf, B. (2004). A tutorial on support vector regression. Statistics and Computing, 14, 199–222.
- Solera, R. (2011). Máquinas de Vectores Soporte para Reconocimiento Robusto de Habla. Madrid, España: Universidad Carlos III de Madrid, Departamento de Teoría de la Señal y Comunicaciones, Tesis doctoral.
- Spathis, C.T. (2003). Audit Qualification, Firm Litigation, and Financial Information: an Empirical Analysis in Greece, International Journal of Auditing, 7 (1) 71-85.
- SPSS (2004). SPSS Classification Trees™ 13.0. Descargado desde www.spss.com el 15 de junio de 2005.
- Srinivasan, A. (1999). Note on the location of optimal classifiers in n-dimensional ROC space. Reporte técnico PRG-TR-2-99. Oxford, Inglaterra: Oxford University, Computing Laboratory.
- Standard & Poor's (2000). Public Finance Criteria 2000. Editado por Standard & Poor's, New York, EUA.
- Standard & Poor's (2006). Annual 2005 Global Corporate Default Study And Rating Transitions. Disponible bajo suscripción en www.standardandpoors.com/ratingsdirect
- Steel, J. (1994). Campari. Banking World, 12, 45-47.
- Steel, S.J., Louw, N. & Bierman, S. (2011). Variable selection for Kernel Classification. Communications in Statistics-Simulation and Computation, 40, 241–258. Doi: 10.1080/03610918.2010.534226
- Stehman, S. (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment*. 62 (1), 77–89. doi:10.1016/S0034-4257(97)00083-7.
- Stone, M. (1974). Cross-validation choice and assessment of statistical predictions. Journal of Royal Statistical Association, 36, 111-147.
- Su, C-F. & Chen, Y-C. (1980). The Rating of Enterprise Financial Condition - Applications of Fuzzy Set to Accounting. Taipei City Financial Monthly, 12, 67–85.
- Sung, T.K., Chang, N. & Lee, G. (1999). Dynamics of Modeling in Data Mining: Interpretive Approach to Bankruptcy Prediction. Journal of Management Information Systems, 16 (1), 63-85.
- Surkan, A.J. & Singleton, J.C. (1990). Neural networks for bond rating improved by multiple hidden layers. *IEEE/INNS International Joint Conference on Neural Networks*, 2, 157-162.
- Suykens, J.A.K. & Vandewalle, J.P.L. (1999). Least squares support vector machine classifiers. Neural Processing Letters, 9 (3), Jun., 293–300.
- Syau, Y., Hsie, H-T. & Lee, E.S. (2001). Fuzzy Numbers in the Credit Rating of Enterprise Financial Condition. Review of Quantitative Finance and Accounting, 17 (4), 351–360.
- Synkey, J.F. (1992). *Commercial Bank Financial Management*. New York, EUA: McMillan Publishing Company, 4ª edición.
- Taffler R.J. (1983). The Assessment of Company Solvency and Performance Using a Statistical Model. Accounting and Business Research, 15, (52), 295-307.
- Taffler R.J. (1984). Empirical Models for the Monitoring of UK Corporations. *Journal of Banking and Finance*,

8, 199-227.

- Tam, K.Y. & Kiang, M.Y. (1992). Managerial applications of neural networks: The case of bank failure predictions. Management Science, 38(7), 926-947.
- Tay, F.E.H. & Cao, L.J. (2002). Modified support vector machines in financial time series forecasting. Neurocomputing, 48, 847-861.
- Taylor, J. D. (1998). Cross-Industry Differences in Business Failure Rates: Implications for Portfolio Management, Commercial Lending Review, Verano 97/98, 13 (1), 36-48.
- Tenenbaum, J., de Silva, V. & Langford, J. (2000). Global Geometric Framework for Nonlinear Dimensionality Reduction. Science, 290 (5500), 2319-2323
- The Financial Crisis Inquiry Commission (2011). The Financial Crisis. Inquiry Report. Final Report of the National Commission on the Causes of the Financial and Economic Crisis in the United States. Pursuant to Public Law 111-21. Descargado el 23 de diciembre de 2011 desde http://www.rydal-meadowbrook.org/sites/default/files/fcic_final_report_full.pdf.
- Theodossiou, P. (1993). Predicting Shifts in the Mean of a Multivariate Time Series Process: An Application in Predicting Business Failures, Journal of the American Statistical Association, 88 (June), 441-449.
- Thomson Financial (2003). Worldscope Datatype Definitions Guide. Issue 3: August-2003, <http://extranet.datastream.com/index.htm>.
- Treacy, W.F. & Carey, M.S. (1998). Credit Risk Rating at Large U.S. Banks, Federal Reserve Bulletin, bajado el 31 de Julio de 2002 desde <http://www.federalreserve.gov/boarddocs/creditrisk/>, Working Paper, November, 897-921.
- Turksen, L.B. (1998). Fuzzy data mining and expert system development. 1998 IEEE International Conference on Systems, Man, and Cybernetics, 2, 2057-2062.
- U.S. Census Bureau (2006). Statistics of U.S. Businesses: 2002: All industries, United States, Census 2000, última modificación 1 de Enero de 2006, bajado el 12 de diciembre de 2006 desde <http://www.census.gov/epcd/susb/2002/us/US--.HTM>.
- Utans, J. & Moody, J. (1991). Selecting neural network architectures via the prediction risk: application to corporate bond rating prediction.. Proceedings, First International Conference on Artificial Intelligence on Wall Street, 9 al 11 de Oct., 35 -41.
- Utgoff, P.E. (1989). Perceptron Tree: a case study in hybrid Utgoff, 1989 concept representations. Connection Science, 1 (4), 377-391.
- Van Gestel, T., Suykens, J.A.K., Baestaens, D-E., Lambrechts, A., Lanckriet, G., Vandaele, B., De Moor, B. & Vandewalle, J. (2001). Financial Time Series Prediction Using Least Squares Support Vector Machines Within the Evidence Framework. IEEE Transactions on Neural Networks, 12 (4), 809-821.
- Van Roy, P. (2006). Is there a difference between solicited and unsolicited bank ratings and if so, why? Working paper No. 120, National Bank of Belgium.
- Vapnik V.N. (1982). Estimation of Dependences Based on Empirical Data. (1979). Moscú, U.R.S.S.: Nauka. Traducido al inglés, (1982). New York, Springer Verlag.
- Vapnik V.N. (1998). Statistical Learning Theory. John Wiley: New York.
- Visauta V., B. (1998). Análisis estadístico con SPSS para Windows. Madrid, España: McGraw-Hill/Interamericana de España SAU., Vol.I.
- Wang, G. & Ma, J. (2011). Study of corporate credit risk prediction based on integrating boosting and random subspace. Expert Systems with Applications, 38 (11), 13871-13878, doi: 10.1016/j.eswa.2011.04.191

- Ward, T.J. (1994). Cash flow information and the prediction of financially distressed mining, oil and gas firms: A comparative study, Journal of Applied Business Research, 10 (3), 78-86.
- Warner, J. (2010). Greek crisis: the world would be a better place without credit rating agencies. The Telegraph. Economics Last: 28 de Abril de 2010. Descargado el 16 de abril de 2012 desde <http://blogs.telegraph.co.uk/finance/jeremywarner/100005241/the-world-would-be-a-better-place-without-credit-rating-agencies/>
- West, D. (2000). Neural network credit scoring models. Computers & Operations Research, 27 (11/12), 1131-1152.
- West, R.R. (1970). An alternative approach to predicting corporate bond ratings. Journal of Accounting Research, 8 (1), 118-125.
- Widrow, B. & Hoff, M. (1960). Adaptive Switching Circuits. IREWESCON Convention Record, Part 4, 96-104. Reimpreso en Anderson, J. & Rosenfeld, E. (eds) (1988). Neurocomputing, Massachusetts, EUA: MIT Press, 126-134.
- Wilson, T. C. (1997a). Portfolio Credit Risk (I). Risk, 10 (9), septiembre, 111-117
- Wilson, T. C. (1997b). Portfolio Credit Risk (II). Risk, 10 (10), octubre, 56-61
- Wilson, N., Chong, K.S. & Peel, M.J. (1995). Neural Network Simulation and the Prediction of Corporate Outcomes: Some Empirical Findings. International Journal of the Economics of Business, 2 (1), 31-50.
- Witten, H. & Frank, E. (2000). Data Mining: Practical Machine Learning Tools and Techniques with Java Implementation. San Mateo, CA, EUA: Morgan Kaufmann Publishers.
- Wong, B.K., Lai, V.S. & Lam, J. (2000). A bibliography of neural network business applications research: 1994-1998. Computers & Operations Research, 27, 1045-1076.
- World Bank (2003). World Development Report 2003: Sustainable Development in a Dynamic World: Transforming Institutions, Growth, and Quality of Life. New York : Oxford University Press, Vol. 1 y 2.
- Yang, B., Janssens, D., Ruan, D., Cools, M., Bellemans, T. & Wets, G. (2012). A Data Imputation Method with Support Vector Machines for Activity-Based Transportation Models, en *Advances in Intelligent and Soft Computing*, 2012, Volume 122/2012, 249-257, DOI: 10.1007/978-3-642-25664-6_29
- Yergin, D. (2009). Three Top Economists Agree 2009 Worst Financial Crisis Since Great Depression; Risks Increase if Right Steps are Not Taken. Entrevista a Roubini, Rogoff y Behraves el 27 de febrero de 2009, 10:22am EST. Descargado el 15 de abril de 2012 desde <http://www.reuters.com/article/2009/02/27/idUS193520+27-Feb-2009+BW20090227>
- Zadeh, L. (1965). Fuzzy sets. Information and Control, 8(3), 338-353.
- Zavgren, C. (1985). Assessing the Vulnerability to Failure of American Industrial Firms: a Logistic Analysis, Journal of Business Finance & Accounting, 12 (1), 19 – 45.
- Zeileis, A. , Hornik, K. , Smola, A. & Karatzoglou, A. (2004), Kernlab - An S4 Package for Kernel Methods in R, *Journal of Statistical Software*, 11, (i09). Descargado el 12 de marzo de 2012 desde <http://EconPapers.repec.org/RePEc:jss:jstsof:11:i09>.
- Zhang, J., Jin, R., Yang, Y. & Hauptmann, A.G. (2003). Modified Logistic Regression: An Approximation to SVM and Its Applications in Large-Scale Text Categorization. Proceedings of the Twentieth International Conference on Machine Learning (ICML-2003), Washington DC, 2003.

ANEXOS

Tabla de Contenidos de los Anexos

Anexo A. Acerca de la concesión crediticia y la predicción de ratings	188
Anexo B. Técnicas utilizadas en clasificación y predicción de ratings	190
Anexo C. Anexos de la muestra de datos.....	192
1. Acerca del rating.....	192
2. Acerca de las variables explicativas y su descripción	195
3. Construcción de la base de datos	198
4. Acerca la descripción de la muestra	204
5. Acerca de la exploración global de los datos.....	207
6. Acerca de la muestra agrupada por rating	218
7. Acerca del análisis de las variables agrupadas	226
8. Acerca de las variables agrupadas por país y sector industrial.....	232
9. Acerca de las anomalías e influencias	253
Anexo D. Revisión de supuestos necesarios para las técnicas estadísticas.	260
1. Análisis de supuestos de técnicas y modelos usados en la fase 1.....	260
2. Evaluación de supuestos y estadísticos de ajuste para la regresión logística binaria en la fase 1	264
3. Análisis de supuestos del análisis discriminante usados en la fase 2 y que difiere de la fase 1	266
4. Evaluación de supuestos y estadísticos de ajuste para la regresión logística multinomial en la fase 2.....	270
Anexo E. Calibración de parámetros	272
1. Calibración de parámetros en la fase 1.	272
2. Calibración de parámetros en la fase 2	284
3. Resultados finales de réplica con SVR (fase 2).....	286

Anexo A. Acerca de la concesión crediticia y la predicción de ratings

Tabla A 1. Listado de variables utilizadas en la literatura financiera para la predicción de quiebras o desequilibrio financiero

Variable conceptual	Composición de la variable	Referencias
tamaño	Log of total assets	Flagg y Giroux (1991)
tamaño	Total assets	Frydman, Altman y Kao (1985)
actividad	Accounts receivable / sales	Beaver (1966)
actividad	Cash / sales	Frydman, Altman y Kao (1985)
actividad	Inventory / sales	Beaver (1966), Edmister (1972), Theodossiou (1993), Zavgren (1985)
actividad	Receivables / inventory	Zavgren (1985)
actividad	Sales / net plant	Zavgren (1985), Becchetti y Sierra (2003)
actividad	Depreciation chages / gross fixed assets	Becchetti y Sierra (2003)
actividad	Sales / total assets	Altman (1968), Frydman, Altman y Kao (1985), Becchetti y Sierra (2003)
financiación	Cash flow / total debt	Frydman, Altman y Kao (1985)
financiación	Fixed assets / total assets	Theodossiou (1993)
financiación	Interest coverage +15	Frydman, Altman y Kao (1985)
financiación	Long-term debt / total assets	Beaver (1966), Altman (1968), Kaplan y Urwitz (1979)
financiación	Market Value Equity / total capitalization	Frydman, Altman y Kao (1985)
financiación	Market Value Equity / total liabilities	Altman (1968)
financiación	Reserves / total assets	Becchetti y Sierra (2003)
financiación	Total debt / total assets	Frydman, Altman y Kao (1985), Flagg y Giroux (1991), Becchetti y Sierra (2003)
financiación	Total debt / total capital	Zavgren (1985)
liquidez	Cash flow of operations / current liabilities	Casey y Bartzak (1985)
liquidez	Cash / current liabilities	Beaver (1966), Edmister (1972)
liquidez	Cash / total assets	Beaver (1966), Zavgren (1985), Casey y Bartzak (1985), Frydman, Altman y Kao (1985), Flagg y Giroux (1991)
liquidez	Current assets / current liabilities	Beaver (1966), Casey y Bartzak (1985), Casey y Bartzak (1985), Frydman, Altman y Kao (1985), Flagg y Giroux (1991)
liquidez	Current assets / sales	Frydman, Altman y Kao (1985)
liquidez	Current assets / total assets	Beaver (1966), Casey y Bartzak (1985), Frydman, Altman y Kao (1985), Spathis (2003)
liquidez	Net working capital / sales	Edmister (1972), Frydman, Altman y Kao (1985)
liquidez	Net working capital / total assets	Beaver (1966), Altman (1968), Theodossiou (1993), Frydman, Altman y Kao (1985), Spathis (2003), Becchetti y Sierra (2003)
liquidez	Quick assets / current liabilities	Beaver (1966), Zavgren (1985), Frydman, Altman y Kao (1985)
liquidez	Quick assets / sales	Frydman, Altman y Kao (1985)
liquidez	Net working capital/ current liabilities	Becchetti y Sierra (2003)
liquidez	Net working capital/medium and long ter	Becchetti y Sierra (2003)
liquidez	Current liabilities/net worth	Becchetti y Sierra (2003)
liquidez	Quick assets / total assets	Frydman, Altman y Kao (1985)
liquidez	receivables + inventory / total assets	Spathis (2003)
rentabilidad	EBIT / total assets	Flagg y Giroux (1991)
rentabilidad	Net income / total assets	Beaver (1966), Zavgren (1985), Casey y Bartzak (1985), Frydman, Altman y Kao (1985), Kaplan y Urwitz (1979)
rentabilidad	Operating income / total assets	Altman (1968), Theodossiou (1993), Becchetti y Sierra (2003)
rentabilidad	Profit / net worth	Becchetti y Sierra (2003)
rentabilidad	EBIT / total debt	Becchetti y Sierra (2003)
rentabilidad	Retained earnings / total assets	Altman (1968), Frydman, Altman y Kao (1985), Flagg y Giroux (1991)
características	pérdidas del a compañía durante eñ año	Spathis (2003)
características	Macroarea location	Becchetti y Sierra (2003)
características	Firm sales/industry sales	Becchetti y Sierra (2003)
características	Size Export status	Becchetti y Sierra (2003)
características	Subcontracting status	Becchetti y Sierra (2003)
características	Strength and proximity of competitors	Becchetti y Sierra (2003)
características	Sales / three largest customers/total sales	Becchetti y Sierra (2003)
características	qualified opinion (going concern)	Flagg y Giroux (1991), Spathis (2003)
características	Age	Becchetti y Sierra (2003)
características	Group membership	Becchetti y Sierra (2003)
características	Tiene o no litigio en el año	Spathis (2003)
sistema de variables	síntomas de quiebra: 3 variables cualitativas con 12% de relevancia	Argenti (1977)
sistema de variables	errores comerciales: 3 variables	Argenti (1977)
sistema de variables	cualitativas con 45% de relevancia fallos en el registro: 4 variables	Argenti (1977)
sistema de variables	cualitativas con 24% de relevancia fallos en la gestión: 6 variables	Argenti (1977)
sistema de variables	cualitativas con 19% de relevancia variable multiescala: z--score de Altman	Argenti (1977)
sistema de variables	para predecir quiebra	Spathis (2003)

Tabla A 2. Listado de variables utilizadas en la literatura financiera para la predicción de rating

Variable conceptual	Composición de la variable	Referencias
tamaño	issue size	Pinches y Mingo (1973)
tamaño	log(total assets)	Surkan y Singleton (1990)
tamaño	sales	Shin y Han (2001), Moro (2004), Ahn y Kim (2011)
tamaño	stockholders' equity	Shin y Han (2001)
tamaño	total assets	Horrigan (1966), Kaplan y Urwitz (1979), Maher y Sen (1997), Chaveesuk et al. (1999), Shin y Han (2001), Huang, Chen et al. (2004), Moro (2004)
tamaño	sales / total assets	Moro (2004), Ahn y Kim (2011)
tamaño	total debt	Chaveesuk et al. (1999), Huang, Chen et al. (2004), Ahn y Kim (2011)
actividad	cash flow before interest and taxes / interest charges	Kaplan y Urwitz (1979)
actividad	coefficient of variation of net income	Kaplan y Urwitz (1979)
actividad	coefficient of variation of total assets	Kaplan y Urwitz (1979)
actividad	construction cost/total cash flow	Surkan y Singleton (1990)
actividad	depreciation/total expense	Shin y Han (2001)
actividad	financial expense/sales	Shin y Han (2001)
actividad	inventories / cost of goods sold	Moro (2004)
actividad	net cash flow/total asset	Shin y Han (2001), Moro (2004), Ahn y Kim (2011)
actividad	revenue growth rate (past 5 year)	Dutta y Shekhar (1988)
actividad	revenue growth rate (projected next 5 year)	Dutta y Shekhar (1988)
actividad	sales / net property plant equipmen	Lee (2007), Ahn y Kim (2011)
actividad	sales per employee	Ahn y Kim (2011)
actividad	sales / net worth	Horrigan (1966), Dutta y Shekhar (1988)
financiación	cash flow from operating activities/current liabilities	Huang, Chen et al. (2004), Ahn y Kim (2011)
financiación	interest / sales	Lee (2007)
financiación	debt/total capital	Surkan y Singleton (1990)
financiación	long term debt / net worth	Kaplan y Urwitz (1979), Chaveesuk et al. (1999), Huang, Chen et al. (2004), Dutta y Shekhar (1988), Moro (2004)
financiación	long term debt / total assets	Pinches y Mingo (1973), Maher y Sen (1997), Moro (2004)
financiación	net worth/ total debt	Horrigan (1966)
financiación	shareholders' equity + long-term debt / fixed assets	Huang, Chen et al. (2004)
financiación	total liabilities/total assets	Shin y Han (2001), Dutta y Shekhar (1988), Huang, Chen et al. (2004), Chaveesuk et al. (1999), Moro (2004), Lee (2007), Ahn y Kim (2011)
liquidez	current asset/current liability	Chaveesuk et al. (1999), Moro (2004), Lee (2007), Ahn y Kim (2011)
liquidez	inventories / current assets	Ahn y Kim (2011)
liquidez	liability/cash asset	Dutta y Shekhar (1988)
liquidez	quick ratio	Huang, Chen et al. (2004)
liquidez	receivables to payables	Lee (2007)
liquidez	short-term debt/current assets	Lee (2007)
liquidez	short-term debt/total capital	Chaveesuk et al. (1999)
liquidez	working capital / sales	Horrigan (1966), Moro (2004)
liquidez	working capital turnover	Shin y Han (2001)
liquidez	working capital/sales	Dutta y Shekhar (1988)
rentabilidad	earning/fixed costs	Dutta y Shekhar (1988)
rentabilidad	earnings per share	Huang, Chen et al. (2004), Ahn y Kim (2011)
rentabilidad	acumulated earnings / total assets	Ahn y Kim (2011)
rentabilidad	net income / total assets	Pinches y Mingo (1973), Kaplan y Urwitz (1979), Moro (2004)
rentabilidad	net income + interest / interest	Pinches y Mingo (1973), Chaveesuk et al. (1999)
rentabilidad	net income before tax/received capitals	Huang, Chen et al. (2004), Lee (2007)
rentabilidad	net income from operations/total asset	Maher y Sen (1997), Lee (2007)
rentabilidad	net operating profit / sales	Horrigan (1966), Shin y Han (2001), Huang, Chen et al. (2004)
rentabilidad	non-operating income/sales	Huang, Chen et al. (2004)
rentabilidad	operating income/received capitals	Huang, Chen et al. (2004)
rentabilidad	operating profit margin	Huang, Chen et al. (2004)
rentabilidad	pre-tax interest expense/income	Surkan y Singleton (1990)
rentabilidad	profit/sales	Dutta y Shekhar (1988), Chaveesuk et al. (1999), Huang, Chen et al. (2004)
rentabilidad	return on investment (or equity)	Surkan y Singleton (1990), Surkan y Singleton (1990), Huang, Chen et al. (2004)
rentabilidad	return on total assets	Huang, Chen et al. (2004)
rentabilidad	times interest earned = EBIT / interest	Huang, Chen et al. (2004), Moro (2004), Lee (2007)
rentabilidad	toll revenue ratio	Surkan y Singleton (1990)
volatilidad	market's beta of each company (systematic market's risk measure)	Kaplan y Urwitz (1979), Maher y Sen (1997)
volatilidad	standard deviation of market's return (unsystematic market's risk measure)	Kaplan y Urwitz (1979)
características	firm classification	Shin y Han (2001)
características	firm type (conglomerado)	Shin y Han (2001)
características	subjective prospect of company	Dutta y Shekhar (1988)
características	subordination status	Horrigan (1966), Maher y Sen (1997), Kaplan y Urwitz (1979), Pinches y Mingo (1973)
características	years after founded	Shin y Han (2001), Ahn y Kim (2011)
características	years of consecutive dividends	Pinches y Mingo (1973)

Anexo B. Técnicas utilizadas en clasificación y predicción de ratings

Tabla A 3. Detalle de artículos publicados donde se replica rating de empresas no-financieras y de bonos corporativos.

Artículo	clases	tipo de clases	técnicas	variables	% acierto	país	muestra (n)	validación	Datos en el Tiempo
Horrigan (1966)	9	AAA ... C	Regres.lineal	6	52,0 - 58,0	EUA	200	holdout	1959-1964, 1961-1964
Pogue y Soldofsky (1969)	4	Aaa Baa	Regres.lineal	6	80,0	EUA	102 y 10	holdout	1961 - 1966
West (1970)	9	Aaa...Baa	Regres.lineal	4	62,0	EUA	150	holdout	1963-1968
Kaplan y Urwitz (1979)	6	Aaa ... B	Regres.lineal	10	55,0	EUA	120+ 140 y 67	holdout	1971,1972, 1970-1974
	6	Aaa ... B	Regres.(Probit)	10	50,0	EUA	120+ 140 y 67	holdout	1971,1972, 1970-1974
Pinches y Mingo (1973)	5	Aa ... B	AD	6	58 - 65	EUA	132 y 48	holdout	1967 y 1968
Dutta y Shekhar (1988)	2	AA v/s noAA	RNRP	10	88,3 - 92,4	EUA	30 y 17	holdout	1983 y 1984
	2	AA v/s noAA	Reg.logística	19	64,7	EUA	30 y 17	holdout	1983 y 1984
Surkan y Singleton (1990)	2	Aaa v/s A1,A2,A3	RNRP	7	88,0	EUA	51 y 35	holdout	1982-1988
Caravaglia (1991)	17	AAA, ..., B, B-, (CCC,CC,C,D) Inversión,	RNCP	87	23,0	EUA	156 y 641	S/I/C	1987
	3	Especulativo, Mala calidad	RNCP	87	84,0	EUA	156 y 641	S/I/C	1987
Utans y Moody (1991)	17	AAA ... B-	Regresión	10	21,4	EUA	196 y 196	5-f cv	S/I/C
	17	AAA ... B-	RN PM	10	29,1	EUA	196 y 196	5-f cv	S/I/C
	17	AAA ... B-	RN PM	10	28,6	EUA	196 y 196	5-f cv	S/I/C
	17	AAA ... B-	RN PM	10	29,6	EUA	196 y 196	5-f cv	S/I/C
Han y Jhee (1993)	4	A1 ... B	Adaline (1985)	26	83,8	Korea	136 y 80	holdout	1985-1987
	4	A1 ... B	Adaline (1986)	26	87,5	Korea	136 y 80	holdout	1985-1987
	4	A1 ... B	Adaline (1987)	26	91,3	Korea	136 y 80	holdout	1985-1987
	4	A1 ... B	AD (1985)	26	53,8	Korea	136 y 80	holdout	1985-1987
	4	A1 ... B	AD (1986)	26	57,5	Korea	136 y 80	holdout	1985-1987
	4	A1 ... B	AD (1987)	26	66,3	Korea	136 y 80	holdout	1985-1987
Kim (1993)	6	Aaa ... B	Regres.lineal	8	36,2	EUA	110/ 58 y 60	holdout	1985-1991
	6	Aaa ... B	AD	8	36,2	EUA	110/ 58 y 60	holdout	1985-1991
	6	Aaa ... B	Regres.logístico	8	43,1	EUA	110/ 58 y 60	holdout	1985-1991
	6	Aaa ... B	RNRP c/ LVQ	8	55,2	EUA	110/ 58 y 60	holdout	1985-1991
	6	Aaa ... B	RBF	8	31,0	EUA	110/ 58 y 60	holdout	1985-1991
Moody y Utans (1994)	17	AAA ... B-	Regres.lineal	10	21,4	EUA	196 y 196	5-f cv	S/I/C
	17	AAA ... B-	RN PM	10	29,6 - 30,6	EUA	196 y 196	5-f cv	S/I/C
	5	AAA ... B-	RN PM	10	63,8 - 85,2	EUA	196 y 196	5-f cv	S/I/C
Maher y Sen (1997)	6	Aaa ... B	Regres.lineal	7	61,7	EUA	179 / 60 y 60	holdout	01.01.90 - 21.12.93
	6	Aaa ... B	RNRP	7	70,0	EUA	179 / 60 y 60	holdout	01.01.90 - 21.12.93
Kwon et al. (1997)	5	A1 ... C	AD	26	58,4 - 61,6	Korea	3085	holdout	1991 - 1993
	5	A1 ... C	OPP	26	70,9 - 73,5	Korea	3085	holdout	1991 - 1993
	5	A1 ... C	RNRP	26	66,5 - 68,0	Korea	3085	holdout	1991 - 1993

Nota: (1) este porcentaje corresponde a la tasa de ajuste de la regresión, las predicciones no se han validado fuera de la muestra. Las siguientes son abreviaciones y sus correspondencias: AD es análisis discriminante; Rlin es regresión lineal; Rlog es regresión logística; RNRP es red neuronal retropropagación; RNCP es una red neuronal Counter-Propagation; RNPM es una red neuronal Propagación Multicapa; RBF es una red neuronal Función de Base Radial; OPP es una red Ordinal Pairwise Partitioning; LIO es leave-one-out; k-cv significa k carpetas de validación cruzada; S/I/C es Sin Información o con información Confusa; I es Inversión (rating AAA...BBB), E es Especulativo (rating BB...CCC) y M es Mala calidad (rating D).

(continúa)

(continuación)

Artículo	clases	tipo de clases	técnicas	variables	% acierto	país	muestra (n)	validación	Datos en el T
Chaveesuk et al. (1999)	6	AAA...B	Regres.logísti	8	53,3	EUA	60 / 30 y 30	holdout	1997 y 1996
	6	AAA...B	Regres.lineal	8	48,3	EUA	60 / 30 y 30	holdout	1997 y 1996
	6	AAA...B	RNRP	8	51,9 - 56,7	EUA	60 / 30 y 30	holdout	1997 y 1996
	6	AAA...B	RBF	8	23,3 - 38,3	EUA	60 / 30 y 30	holdout	1997 y 1996
	6	AAA...B	LVQ	8	36,7	EUA	60 / 30 y 30	holdout	1997 y 1996
Shin y Han (2001)	5	A1...C	AD	12	60,0	Korea	3486 y 400	S/I/C	1991-1995
	5	A1...C	CBR+GA	12	62 - 70	Korea	3486 y 400	S/I/C	1991-1995
	5	A1...C	CBR	12	61 - 62	Korea	3486 y 400	S/I/C	1991-1995
	5	A1...C	ID3	12	59,0	Korea	3486 y 400	S/I/C	1991-1995
Rovira et al. (2004)	2	AAA...BBB v/s BB...D	RBF	21	78,6	EUA+E+ C+J	319 , 160 y 159	holdout	2001
Huang et al. (2004)	5	AAA...BB	Reg.logística	6	73 y 76	Taiwan	74	10-cv y L-1-O	1998 a 2002
	5	AAA...BB	SVM	6	80 y 80	Taiwan	74	10-cv y L-1-O	1998 a 2002
	5	AAA...BB	RN RP	6	76 y 74	Taiwan	74	10-cv y L-1-O	1998 a 2002
	5	AAA...BB	Reg.logística	16	70 y 70	Taiwan	74	10-cv y L-1-O	1998 a 2002
	5	AAA...BB	SVM	16	77 y 76	Taiwan	74	10-cv y L-1-O	1998 a 2002
	5	AAA...BB	RN RP	16	76 y 74	Taiwan	74	10-cv y L-1-O	1998 a 2002
	5	AA...B	Reg.logística	5	77 y 75	EUA	265	10-cv y L-1-O	1991 a 2000
	5	AA...B	SVM	5	79 y 80	EUA	265	10-cv y L-1-O	1991 a 2000
	5	AA...B	RN RP	5	80 y 81	EUA	265	10-cv y L-1-O	1991 a 2000
	5	AA...B	Reg.logística	14	75 y 75	EUA	265	10-cv y L-1-O	1991 a 2000
	5	AA...B	SVM	14	80 y 80	EUA	265	10-cv y L-1-O	1991 a 2000
Moro (2004)	2	AAA v/s BB	AD	13	1 y 62	EUA	84	S/I/C	1998 y 1999
	2	AAA v/s BB	SVM radial	13	95 - 97	EUA	84	S/I/C	1998 y 1999
	2	AAA v/s BB	SVM espiral	13	65 - 100	EUA	84	S/I/C	1998 y 1999
Rovira et al. (2005)	2	AAA v/s BB	AD y logit	10 y 32	81 - 89	EUA, UE, Japón	1076	2-cv	2002
	2	AAA v/s BB	SVM radial	10 y 32	73 - 77	EUA, UE, Japón	1076	2-cv	2002
Lee (2007)	5	AAA, AA, A, B, C	AD	10	67,0	Corea	3017	holdout (80;20)%	1997 a 2002
	5	AAA, AA, A, B, C	CBR	10	63,4	Corea	3017	holdout (80;20)%	1997 a 2002
	5	AAA, AA, A, B, C	RN	10	55 a 60	Corea	3017	holdout (60;20;20)%	1997 a 2002
	5	AAA, AA, A, B, C	SVM	10	67,0	Corea	3017	5-cv y holdout	1997 a 2002
Ahn y Kim (2011)	5	A1, A2, A3, B+C	RN	14	65,6	Corea	1295	5-cv y holdout	2002
	5	A1, A2, A3, B+C	RN Forward	14	67,1	Corea	1295	5-cv y holdout	2002
	5	A1, A2, A3, B+C	RN backeard	14	67,0	Corea	1295	5-cv y holdout	2002
	5	A1, A2, A3, B+C	SVM	14	57,3	Corea	1295	5-cv y holdout	2002
	5	A1, A2, A3, B+C	SVM Forward	14	68,0	Corea	1295	5-cv y holdout	2002
	5	A1, A2, A3, B+C	SVM Backw.	14	67,6	Corea	1295	5-cv y holdout	2002

Nota: Las siguientes son abreviaciones y sus correspondencias: AD es análisis discriminante; Rlin es Regresión Lineal; Rlog es regresión logística; RNRP es red neuronal retropropagación; RNCP es una red neuronal Counter-Propagation; RNPM es una red neuronal Propagación Multicapa; RBF es una red neuronal Función de Base Radial; OPP es una red Ordinal Pairwise Partitioning; L1O es leave-one-out; k-cv significa k carpetas de validación cruzada; S/I/C es Sin Información o con información Confusa; I es Inversión (rating AAA...BBB), E es Especulativo (rating BB...CCC) y M es Mala calidad (rating D).

Fuente: elaboración propia.

Anexo C. Anexos de la muestra de datos

C.1. Acerca del rating

Tabla A 4. Clases genéricas de rating asignadas por S&P y su descripción.

Categoría	Descripción de las características del emisor calificado y su rating
AAA	Es el mayor rating crediticio asignado por Standard & Poor's, que indica una capacidad extremadamente fuerte del deudor para resolver sus obligaciones financieras.
AA	Capacidad muy fuerte para satisfacer sus obligaciones financieras. Difiere del más alto rating (AAA) solamente en un pequeño grado.
A	Indica una fuerte capacidad para cumplir sus exigencias financieras, pero es algo más susceptible a efectos nocivos por cambios en las circunstancias y condiciones económicas que aquellos emisores calificados con AA.
BBB	Adecuada capacidad para satisfacer sus compromisos financieros. Sin embargo, algunas condiciones económicas cambiantes o adversas pueden probablemente conducir a una debilitada situación financiera del emisor para resolver sus obligaciones.
BB	Indica una situación menos vulnerable que los deudores clasificados en B. El emisor enfrenta claras incertidumbres y su exposición es adversa en sus negocios o frente a las condiciones económicas y financieras generales, de tal manera que ellas podrían conducirle a una incapacidad para de resolver sus compromisos financieros.
B	Indica un escenario más vulnerable que la clasificación BB, aunque el deudor tiene aún la capacidad para resolver sus obligaciones financieras. Las condiciones de su actividad o de la economía probablemente deteriorarán su capacidad financiera o bien las intenciones del deudor para resolver sus compromisos.
CCC	Actualmente vulnerable, aunque aún cumple con sus obligaciones financieras. El deudor depende del ambiente favorable y condiciones económicas y financieras para resolver sus compromisos financieros.
CC	Actualmente altamente vulnerable. Apenas cumple con sus obligaciones financieras, debido fundamentalmente a un actual entorno favorable, aunque incierto.
SD	Significa <i>Default Selectivo</i> . Es una clasificación distinta de las anteriores y que se diferencia del <i>default general</i> (D) porque el emisor sólo ha incurrido en impago con determinadas obligaciones (las que pueden ser muchas), pero no se trata del impago de todas las obligaciones. Cabe hacer notar que esta separación es una distinción que sólo ha definido Standard & Poor's. Las otras agencias de rating, Moody's Investors Service y Fitch Rating, conceden el mismo nivel de fallido tanto si ha incumplido algún tipo de deuda o si lo ha hecho completamente.
D	El emisor ha incumplido sus compromisos de deuda. Técnicamente, el emisor ha caído en fallido.
Calificadores + ó -	Estos símbolos indican que en algún momento futuro los ratings pueden cambiar en forma positiva (+) o negativa (-). De esta manera, un signo más (+) o menos (-) puede ser agregado al rating que va desde AA hasta CCC para demostrar la situación relativa del emisor dentro de una categoría.

Fuente: Elaboración propia, basada en datos de López (1996), Standard & Poor's (2000).

La muestra tiene dos niveles de rating cada clase etiquetada en el nivel 1 tiene una clase asignada en el nivel 2. Los vínculos entre las clases de ambos niveles de rating se exponen en la siguiente figura

Figura A 1. Correspondencia en la muestra entre clases de rating de los dos niveles

Etiqueta de Rating nivel 1	Nº de casos	Etiqueta de Rating nivel 2	Nº de casos
AAA	8	AA-AAA	50
AA+	2	A	212
AA	15	BBB	340
AA-	25	BB	299
A+	53	B	197
A	80	C	42
A-	79	D	37
BBB+	98	Total	1177
BBB	136		
BBB-	106		
BB+	77		
BB	101		
BB-	121		
B+	95		
B	70		
B-	32		
CCC+	20		
CCC	14		
CCC-	2		
CC	6		
C	0		
SD	4		
D	33		
Total	1177		

Tabla A 5. Sectores Industriales, sus abreviaciones y codificación

Datastream industrial classification: Level 3 (INDC3)			Datastream industrial classification: Level 4 (INDC4)		
Etiqueta	Código	Descripción	Etiqueta	Código	Descripción
RESOR	00	Resources	MNING	04	Mining
			OILGS	07	Oil & Gas
BASIC	10	Basic Industries	CHMCL	11	Chemicals
			CNSBM	13	Construction & Building Materials
			FSTPA	15	Forestry & Paper
			STLOM	18	Steel & Other Metals
GENIN	20	General Industrials	AERSP	21	Aerospace & Defence
			DIVIN	24	Diversified Industrials
			ELTNC	25	Electronic & Electrical Equipment
			ENGEN	26	Engineering & Machinery
CYCGD	30	Cyclical Consumer Goods	AUTMB	31	Automobiles & parts
			HHOLD	34	Household Goods & Textiles
NCYCG	40	Non-Cyclical Consumer Goods	BEVES	41	Beverages
			FOODS	43	Food Producers & Processors
			HLTHC	44	Health
			PERSH	47	Personal Care & Household
			PHARM	48	Pharmaceuticals & Biotechnology
			TOBAC	49	Tobacco
CYSER	50	Cyclical Services	RTAIL	52	General Retailers
			LESUR	53	Leisure & Hotels
			MEDIA	54	Media & Entertainment
			SUPSV	58	Support Services
			TRNSP	59	Transport
NCYSR	60	Non-Cyclical Services	FDRET	63	Food & Drug Retailers
			TELCM	67	Telecommunication Services
UTILS	70	Utilities	ELECT	72	Electricity
			UTILO	77	Utilities, other
TOTLF	80	Financials	BANKS	81	Banks
			INSUR	83	Insurance
			LIFEA	84	Life Assurance
			INVSC	85	Investment Companies
			RLEST	86	Real Estate
			SPFIN	87	Speciality & Other Finance
			INVET	89	Investment Entities
ITECH	90	Information Technology	INFOH	93	Information Technology Hardware
			SFTCS	97	Software & Computer Services

Nota: Cada INDC4 (índice de nivel 4 o Industry indice) se vincula a un INDC3 (índice de nivel 3 o Economic indice), debido a que es una subagrupación de este último. Este vínculo se puede observar fácilmente con la codificación de cada uno de ellos. Ambos se vinculan a través del primer dígito del código. Por ejemplo, el código 11 de INDC4 (Chemicals) pertenece al grupo 10 de INDC3 (Basic Industries).

Fuente: Thomson Financial

C.2. Acerca de las variables explicativas y su descripción

En las siguientes tablas se exponen las variables de la muestra, su identificación, su grupo conceptual (tipificación) y una descripción de su contenido o cálculo.

Tabla A 6. Variables de rating, identificación y caracterización de las compañías

	Nombre	Variable	Descripción [variables originales de la base de datos]
Rating	I_dscd	Identificación	Código único de Datastream, utilizado por Thomson para la identificación inequívoca de cada compañía
	R_lpmla1	Rating nivel 1	Rating de largo plazo en moneda local nivel 1
	R_lpmla2	Rating nivel 2	Rating de largo plazo en moneda local nivel 2
Características	C_pais	País	Nación del domicilio de la compañías
	C_indc3	Sector industrial nivel 3	Datastream industrial classification: Level 3 (Fuente originaria: Financial Times)
	C_indc4	Sector industrial nivel 4	Datastream industrial classification: Level 4
	C_opaud	Opinión de los auditores	Opinión de los auditores. Ésta puede ser: (a) Not audited (b) No audit report in abbreviated version, (c) Partial audit, (d) Consolidated statements appear not to be audited, but parent company statements audited, (e) Qualified, and (f) Unqualified.

Fuente: Thomson Financial y Standard & Poor's.

Tabla A 7. Variables de tamaño y actividad de las compañías

	Nombre	Variable	Unidad de medida	Descripción [variables originales de la base de datos]
Tamaño	t_vtas	ventas	miles de US\$	Net Sales or Revenues [wc01001]
	t_vm	valor en bolsa	miles de US\$	Market Capitalization [MV]
Actividad	a_s-ta	rotación operacional	miles de u.m.l / miles de u.m.l.	Sales / Total Assets [wc01001 / wc02999]
	a_cf-s	flujo de efectivo	miles de u.m.l / miles de u.m.l.	Cash Flow / Sales [wc04201 / wc01001]
	a_vvtas	variación de ventas	miles de u.m.l / miles de u.m.l.	Net Sales (del año en curso) / Net Sales (del año anterior) -1 [(wc01001 _t / wc01001 _{t-1}) -1]

NOTA: "u.m.l." significa unidades de moneda local del país de origen de la compañía. Entre corchetes se encuentran los códigos de las cuentas utilizadas para extraer la información desde Thomson Financial.

Fuente: Thomson Financial y Standard & Poor's.

Tabla A 8. Variables de liquidez de las compañías

	Nombre	Variable	Unidad de medida	Descripción [variables originales de la base de datos]
Liquidez	l_s-wc	cobertura de capital de trabajo	miles de u.m.l / miles de u.m.l.	Net Sales / Working Capital [wc01001 / (wc02201-wc03101)]
	l_wc-ltd	financiamiento de largo plazo	miles de u.m.l / miles de u.m.l.	Working Capital / Long Term Debt [(wc02201-wc03101) / wc03251]
	l_wc-ta	proporción de inversiones de corto plazo	miles de u.m.l / miles de u.m.l.	Working Capital / Total Assets [(wc02201-wc03101) / wc02999]
	l_cl-ta	proporción de deuda corriente sobre activo	miles de u.m.l / miles de u.m.l.	Current Liabilities / Total Assets [wc03101 / wc02999]
	l_quick	necesidad de efectivo	miles de u.m.l / miles de u.m.l.	Quick Ratio = (Cash & Equivalents + Receivables (Net)) / Current Liabilities Total [(wc02001+wc02051) / wc03101]
	l_cas-ta	proporción de inversiones	miles de u.m.l / miles de u.m.l.	Current Assets - Stocks / Total Assets [(wc02201-wc02101) / wc02999]
	l_cas-cl	necesidad de efectivo de mediano plazo	miles de u.m.l / miles de u.m.l.	Current Assets - Stocks / Current Liabilities [(wc02201-wc02101) / wc03101]
	l_ca-cl	capital de trabajo	miles de u.m.l / miles de u.m.l.	Current Assets / Current Liabilities [wc02201 / wc03101]
	l_c-cl	necesidad de efectivo de corto plazo	miles de u.m.l / miles de u.m.l.	Cash & Short Term Investments/Current Liabilities [wc02001 / wc03101]
	l_i-tca	nivel de stocks	miles de u.m.l / miles de u.m.l.	Inventories / Total Current Assets [wc02101 / wc02201]
	l_ca-ta	proporción de inversiones corrientes	miles de u.m.l / miles de u.m.l.	Current Assets / Total Assets [wc02201 / wc02999]
l_cl-tl	proporción de deuda corriente	miles de u.m.l / miles de u.m.l.	Current Liabilities / Total Liabilities [wc03101 / wc03351]	

NOTA: "u.m.l." significa unidades de moneda local del país de origen de la compañía. Entre corchetes se encuentran los códigos de las cuentas utilizadas para extraer la información desde Thomson Financial.

Fuente: Thomson Financial y Standard & Poor's.

Tabla A 9. Variables de financiación de las compañías

	Nombre	Variable	Unidad de medida	Descripción [variables originales de la base de datos]
Financiación	f_cf-td	cobertura sobre la deuda	miles de u.m.l / miles de u.m.l.	Cash Flow (from Op.activ.) / Total Debt [wc04201 / wc03351]
	f_ltd-ce	largo plazo	miles de u.m.l / miles de u.m.l.	Long Term Debt / Common Equity [wc03251 / wc03501]
	f_fa-ce	financiación de infraestructura	miles de u.m.l / miles de u.m.l.	Fixed Assets / Common Equity [wc02501 / wc03501]
	f_td-ta	proporción agregada	miles de u.m.l / miles de u.m.l.	Total Debt / Total Assets [wc03351 / wc02999]
	f_dp-e	dividendos	miles de u.m.l / miles de u.m.l.	Dividend Payout / Earnings = (Common Dividends (Cash) / (Net Income before Preferred Dividends - Preferred Dividend Requirement) [wc04551 / (wc01551-wc01701)]
	f_mve-tl	mercado v/s valor contable	miles de u.m.l / miles de u.m.l.	Market Value Equity / Book Value of Total Liabilities [MV / wc03351]
	f_td-ce	porción fuentes externas	miles de u.m.l / miles de u.m.l.	Total Debt / Common Shareholders Equity [wc03351 / wc03501]

NOTA: "u.m.l." significa unidades de moneda local del país de origen de la compañía. Entre corchetes se encuentran los códigos de las cuentas utilizadas para extraer la información desde Thomson Financial.

Fuente: Thomson Financial y Standard & Poor's.

Tabla A 10. Variables de rentabilidad y volatilidad de las compañías

	Nombre	Variable	Unidad de medida	Descripción [variables originales de la base de datos]
Rentabilidad	g_ebit-i	cobertura de intereses	miles de u.m.l / miles de u.m.l.	EBIT / Tot Int Expense [wc01751 / wc01251]
	g_nia-ta	rentabilidad sobre inversión	miles de u.m.l / miles de u.m.l.	Net Income Available to Common / Total Assets [wc01551 / wc02999]
	g_ebit-s	rentabilidad comercial	miles de u.m.l / miles de u.m.l.	EBIT / Sales [wc01751 / wc01001]
	g_ronfa	rentabilidad sobre infraestructura	miles de u.m.l / miles de u.m.l.	Return On Net Fixed Assets [wc01751 / wc02501]
	g_ebit-a	rentabilidad sobre inversión	miles de u.m.l / miles de u.m.l.	EBIT / Total Assets [wc01751 / wc02999]
	g_roe	rentabilidad sobre patrimonio	miles de u.m.l / miles de u.m.l.	Return On Equity [wc01751 / wc03501]
	g_re-ta	capacidad de autofinanciamiento	miles de u.m.l / miles de u.m.l.	Retained Earnings / Total Assets [wc03495 / wc02999]
Volatilidad	v_vol250	Indicador de volatilidad bursátil	% de u.m.l.	Volatility 250 days [060E] (Volatilidad anual de días hábiles de las cotizaciones bursátiles. Porcentaje de volatilidad bursátil que compara la rentabilidad diaria con su rentabilidad media móvil, es decir, su cálculo es $\sqrt{\left(\frac{\sum_{i=1}^{250} \left[\left(\ln \frac{x_i}{x_{i-1}} \right) - Prom.Movil_{de250días} \left(\ln \frac{x_i}{x_{i-1}} \right) \right]^2}{249} \right) * 250} \times 100$ donde x_i es el precio accionario de la compañía).

NOTA: “u.m.l.” significa unidades de moneda local del país de origen de la compañía. Entre corchetes se encuentran los códigos de las cuentas utilizadas para extraer la información desde Thomson Financial.

Fuente: Thomson Financial y Standard & Poor’s.

C.3. Construcción de la base de datos

Para el desarrollo de la presente tesis se ha construido una muestra a partir de dos bases de datos cuyas fuentes primarias difieren en dos aspectos: i) en el proveedor de información y ii) en las variables que la conforman. Una de las bases de datos contiene ratings de 18.909 emisores de todo el mundo, desde el 10 de mayo de 1949 hasta el 7 de septiembre de 2003. La compañía que proveyó dicha información fue Standard & Poor's, y el formato original de la información es texto estándar (del tipo ASCII). La otra base de datos, cuyo proveedor es Thomson Financial contiene información financiera, comercial, económica y contable²⁹. La forma como se ha accedido a esta información ha sido a través de una conexión de Internet, utilizando dos tipos de ingreso: i) su Intranet, ii) empleando el software Datastream Advance 3.5³⁰ (este paquete computacional incluye macros que son instaladas sobre el entorno de Excel y facilitan el acceso de los datos)³¹. La adaptación de las bases de datos se ha elaborado por separado y por etapas. El objetivo final ha sido la elaboración de una base de datos única para utilizar en el presente trabajo. Genéricamente se pueden dividir estas etapas en: a) captura de datos, b) diseño y construcción de la base de datos y de los módulos de consulta y exportación de información, y c) generación de un nexo entre ambas bases de datos y su posterior evaluación. A continuación se presenta un resumen de las tareas y etapas llevadas a cabo en la creación de las bases de datos existentes.

En primer lugar, se destacan las tareas correspondientes a la adaptación de la base de datos de rating que proviene de Standard & Poor's:

1. Importación de datos. Inicialmente, este tipo de datos estaba contenido en un conjunto de ficheros en código ASCII con campos de ancho fijo (no delimitado), y una vez reconocido el contenido de los datos y su estructura se procedió a su importación hacia el formato gestionado por Access.
2. Depuración de la base de datos. Fue necesario filtrar aquellas entradas de datos que no ofrecían información relevante y aquellas que generaban distorsiones en las consultas. Se filtraron registros con datos del emisor pero sin rating ni fecha, caracteres sin sentido lógico generados por el proceso de importación de datos, y se eliminaron los registros duplicados.

²⁹ Los datos de este proveedor son generados desde las siguientes fuentes: Thomson Financial, Worldscope, Datastream, Financial Times Stock Exchange (FTSE), Morgan Stanley Capital International (MSCI) e Institutional Broker's Estimate System (I/B/E/S). De ellas sólo las dos últimas no son utilizadas para la construcción de la base de datos de este proyecto.

³⁰ En adelante Advance y Thomson serán referencias de Datastream Advance 3.5 y Thomson Financial, respectivamente. Además, Advance es propiedad de Datastream International Limited y de Thomson Financial. Además, para obtener los datos desde Thomson Financial, el acceso a la Intranet es a través de la siguiente URL: <http://extranet.datastream.com/index.htm>.

³¹ En adelante Access, Visual Basic y Excel serán referencias de Microsoft Access 2000 versión 6.0, Microsoft Visual Basic versión 6.0 y Microsoft Excel 2000 versión 9.0, respectivamente, cuyas marcas registradas y derechos de copia pertenecen a Microsoft Corporation.

3. Construcción de “consultas” predefinidas y manipulación de datos. Access permite la utilización de “consultas” para generar peticiones de datos en base a variables predeterminadas. Dichas consultas se han creado para resolver preguntas específicas a cerca de los ratings. El output de éstas se ha establecido de tal manera que la captura de datos desde otros programas (SPSS³² y Excel) sea lo más eficiente posible.
4. Preparación de los datos para el enlace de la base de datos. Todas las tablas de esta base de datos se han indexado por un string único de identificación de Standard & Poor’s, que identifica a cada emisor en forma inequívoca y separable del país de origen.

En forma paralela, se ha trabajado en la adaptación de la segunda base de datos. Ésta contiene información de variables económico – financieras, y es provista por Thomson Financial. A continuación se exponen los pasos llevados a cabo:

1. Importación, reconocimiento de los datos iniciales y su verificación. En una primera etapa se han recogido aquellos potenciales datos que serán utilizados en el presente trabajo, y que han sido descritos anteriormente. Los datos extraídos se han manipulado desde Excel. Finalmente, una vez importados los datos desde las aplicaciones de Thomson Financial se verificaron que los datos obtenidos fueran veraces y confiables.
2. Creación de tablas y consultas. Con los datos soportados sobre Excel se han creado tablas dinámicas y tablas con filtros de datos para su análisis. Dichas consultas han servido para resolver dudas específicas acerca de las compañías listadas.
3. Generación de variables nuevas. En esta etapa se han creado dos tipos de nuevas variables: i) ratios financieras calculadas sobre la base de partidas contables e información bursátil, y ii) identificadores del sector industrial y del país al que pertenece cada compañía. Para ello, también se han establecido formatos estándar (formato de los campos, tamaño de archivos y largo de registros) para la exportación de datos a otros programas (SPSS y MS Access).
4. Preparación de los datos para el enlace final de las bases de datos. En este caso, el identificador maestro elegido ha sido un código interno utilizado por Thomson Financial para la manipulación de los datos de las compañías e instrumentos financieros sobre las cuales tiene información.

El enlace de las compañías entre las dos bases de datos se intentó utilizando diversos códigos estándares (entre los más conocidos están CEDEL, CINS, CUSIP, ISIN, SEDOL). Sin embargo, dicho proceso no tuvo éxito, por lo que el vínculo entre las compañías de ambas bases de datos se ha llevado a cabo a través de sus nombres. Una vez que se ha logrado la correcta identificación, se han enlazado

³² En adelante, SPSS será la abreviación en este documento de SPSS for Windows versión 11.0, cuya propiedad y registro le pertenece a SPSS Inc.

los códigos identificadores de cada una de las bases de datos: “Entity ID” de Standard & Poor’s y “DSCD” de Thomson Financial. En los procesos de vínculo se usaron 6 variables clave:

Nombre de la variable usada	Fuente*	Nombre original	Descripción del proveedor de datos
ENTSP	Archivo ERH de S&P	Entity Published Name	Entity name used by Standard & Poor’s for publishing purposes.
BNAM	Archivo IMH de S&P	Entity Name (Issuer)	Legal name for a given entity.
COUNTRY	Archivo ERH de S&P	Country Code	Three-letter code that identifies the issuer's country of domicile.
DS_NAME	Worldscope	WC06001	Company Name
DS_COMPANAME	Worldscope		
DS_CNAME	Worldscope	BNAME	The full name of the bond issuer
NATION	Worldscope	WC06026	It represents the country in which the company is domiciled. NATION will generally correspond with the country under which the company is followed on Worldscope, indicated by NATION CODE, with a small number of exceptions.

NOTAS: (*) los archivos de S&P son de tres tipos: ERH (Entity Ratings History), IMH (Issue/Maturity [Ratings] History) e IRH (Instrument Ratings History).

FUENTE: Standard & Poor’s (www.standardandpoors.com) y Worldscope pertenece a Thomson Financial Limited (2003).

La elección de estas seis variables responde al hecho que cada trío pertenece a ambas bases de datos, y de ellas una hace referencia al país, la otra al nombre de la compañía según el listado de empresas y la última al nombre de la compañía que emite la deuda. Los algoritmos que han buscado identificar el vínculo entre las compañías que se encuentran en las dos bases de datos (de S&P y de Thomson Financial) han incluido procesos de reconocimiento iterativo entre los nombres de las compañías y su país. Luego de reconocer cada posible coincidencia, ésta se separaba del resto de datos para luego ser revisada individualmente.

Los pasos que se han considerado en este proceso de vínculo entre ambas bases de datos son las siguientes:

1. Refinación de la base inicial de datos de S&P. Se incluyeron en el listado de búsqueda sólo los datos de las corporaciones de la industria no financiera ni de seguros³³, pertenecientes a los países de Europa desarrollada³⁴, Estados Unidos, Canadá y Japón, que tuvieran rating de largo plazo en moneda local durante los años 1995 a 2002.
2. Creación de un listado único de datos de empresas sobre el cual se extrajera la información desde Thomson Financial. Este listado es el que se usó para encontrar equivalencias en su homólogo de S&P. Debido a que las empresas que están listadas en la base de datos de Thomson Financial no se encuentran en una única lista, se confeccionó una a partir de listadas parciales. Para ello, se utilizaron dos tipos de listados:

³³ Particularmente aquellas que tienen la clasificación de “Corporate” o “Utility” en la variable “Entity Sub sector” del archivo tipo ERH de S&P.

³⁴ Los países elegidos de Europa son Austria, Bélgica, Dinamarca, Finlandia, Francia, Alemania, Grecia, Irlanda, Italia, Luxemburgo, Países bajos, Portugal, España, Suecia, Reino Unido, Chipre, Islandia, Noruega y Suiza.

- a. las listas de compañías de cada uno de los países seleccionados en el punto anterior (en esta base de datos el nombre del listado para cada país está conformado por el prefijo “LTOTMK” seguido por las iniciales de cada país, por ejemplo, “ES” para el caso español), y
 - b. las compañías de listados de carteras de amplia utilización financiera: DJ Euro (cuyo nombre es DJ STOXX:EUROPE) y S&P 1500 (cuyo nombre es S&P 1500 Super Composi.:UNITED STATES).
3. Proceso de verificación automatizado de coincidencias entre los nombres y países de ambas base de datos. En este proceso de verificación se compararon los nombres de las compañías y países de ambas bases de datos, para que coincidieran. Este proceso iterativo tenía la siguiente estructura

Comparar $nombre_i$ con $nombre_j$ con la $regla_k$ hasta fin del listado

Si $nombre_i = nombre_j \implies$ vincular identificadores y separarlos

Si $nombre_i \neq nombre_j \implies$ pasar a la siguiente $regla_k$

Fin del proceso de verificación con $regla_k$

La primera regla creada fue la comparación literal de nombres y países. Luego se realizaron cambios en las comparaciones de nombres, pero siempre el país debía coincidir en forma estricta. Las reglas que se fueron incorporando durante las sucesivas iteraciones, son las siguientes:

- ✓ considerar equivalencia entre letras mayúsculas y letras minúsculas,
- ✓ sustitución de caracteres especiales (% , & , \$, @ , * , etc.) por el carácter “vacío”,
- ✓ limpiar los espacios y juntar siglas, por ejemplo, “nnnnnnnnnnn S.A.” por “nnnnnnnnnn SA”
- ✓ sustitución y equivalencia de abreviaturas especiales para cada país, por ejemplo, AG en Alemania y Austria, y SPA en Italia
- ✓ exclusión de artículos, adjetivos y características de nombres de compañías genéricamente usados (el, la, the, Inc., Co.),
- ✓ sustitución de abreviaturas estándares (intl = international, glb = global, comms = communications).

Las primeras reglas que aparecen en este listado otorgan mayor confiabilidad o certeza en la vinculación, y en la medida que se agregan las siguientes reglas, hay más posibilidades de que el vínculo realizado sea incorrecto, debido a que los supuestos que subyacen de estas reglas pueden ser incorrectos (por ejemplo, que “intl \neq international”, o bien, que la eliminación de alguna palabra constituyese un elemento diferenciador entre las compañías).

Luego de este proceso de verificación automatizada surgieron cuatro grupos de datos:

- i) un grupo de compañías que coincidían unívocamente en los nombres y países de las dos bases de datos,
 - ii) otro grupo de compañías que coincidían parcialmente en los nombres y totalmente en los países,
 - iii) otro grupo de compañías cuyos nombres coincidían parcialmente con más de un nombre del listado de la otra base de datos, pero que coincidían totalmente en el país, y
 - iv) el restante de compañías que no coincidían en los nombres.
4. Revisión manual de las compañías resultantes. De los grupos i), ii) y iii) del punto anterior, se revisó manualmente cada compañía por su nombre y país, de tal manera que no hubiesen empresas repetidas o que a simple vista fuesen distintas.
5. Se seleccionó el conjunto de datos del año 2002 para comprobar la consistencia entre los datos financieros. Se eliminaron todos los registros repetidos, los que tenían valores perdidos en exceso (más del 70% de los datos cuantitativos), las compañías que pudieran tener los siguientes tipos de errores:
- Por error en la grabación o codificación. Para verificar que esto no haya ocurrido, se analizaron las frecuencias de distribución y los valores que estuviesen fuera de valores permitidos (por ejemplo, que el valor patrimonial bursátil fuese cero). Los errores fueron eliminados del conjunto de datos, y sólo se encontró un caso en que el total pasivo es negativo y un caso en que el inventario es negativo. Ambos eventos son producto de provisiones y ajustes contables, cuya interpretación económica no tiene sentido, pero los datos son precisos y adecuados.
 - Por inclusión de datos de una población distinta a la deseada (por ejemplo, que las compañías tuviesen como actividad principal la banca). Dichos casos se eliminaron de la base de datos.
 - Debido a que la variable de la compañía tiene un valor extraordinario con relación a las restantes. Este tipo de casos se estudió con detalle y no se eliminó de la base de datos.
6. Finalmente se realizaron los cálculos aritméticos para la creación de los variables descritas desde la Tabla A 6 a la Tabla A 10, de esta sección del Anexo. Es decir se realizaron los siguientes cálculos:

- Para las variables de tamaño se dividieron los datos originales, expresados en unidades monetarias locales, por los tipos de cambios al 31 de diciembre de 2002 según información proporcionada por el FMI, para dejar las cifras expresadas en US\$ como patrón de referencia. Los siguientes coeficientes son los denominadores utilizados en la división:

<u>País</u>	<u>Paridad</u>	<u>País</u>	<u>Paridad</u>	<u>País</u>	<u>Paridad</u>
Alemania	0,953562	Finlandia	0,953562	Noruega	6,9657
Austria	0,953562	Francia	0,953562	Países Bajos	0,953562
Bélgica	0,953562	Grecia	0,953562	Portugal	0,953562
Canadá	1,5796	Italia	0,953562	Reino Unido	0,620424
Dinamarca	7,0822	Japón	119,9	Suecia	8,825
España	0,953562	Luxemburgo	0,953562	Suiza	1,3868

Estos datos se han descargado desde el International Monetary Fund, el 21 de agosto de 2004 en su página web <http://www.imfstatistics.org/imf/>

- Para los ratios que se expresan como cociente se dividieron las respectivas partidas contables.
- Para la variable de variación ventas se calculó la variación de ventas con respecto al año anterior de cada compañía.

C.4. Acerca la descripción de la muestra

Tabla A 11. Distribución de la muestra por rating por país y por sector industrial

Rating Nivel 2	c_indc3: sector industrial									Total	%
	BASIC	CYCGD	CYSER	GENIN	ITECH	NCYCG	NCYSR	RESOR	UTILS		
AA-AAA	1	2	7	4	1	17	3	6	9	50	4%
A	25	7	32	30	9	39	18	19	33	212	18%
BBB	53	33	88	33	16	32	18	33	34	340	29%
BB	55	26	72	31	27	33	10	33	12	299	25%
B	17	11	47	12	45	28	18	14	5	197	17%
C	5	1	12	2	5	2	10	4	1	42	4%
D	5	4	5	3	3	2	11	3	1	37	3%
Total	161	84	263	115	106	153	88	112	95	1177	100%
%	14%	7%	22%	10%	9%	13%	7%	10%	8%	100%	

Tabla A 12. Distribución de la muestra por país y por rating

Rating Nivel 2	Bloque económico				Total	%
	EUROPE	JAPAN	U.S.	CANADA		
AA-AAA	9	15	24	2	50	4%
A	49	7	143	13	212	18%
BBB	67	3	235	35	340	29%
BB	12	1	267	19	299	25%
B	4	0	182	11	197	17%
C	2	0	38	2	42	4%
D	2	0	33	2	37	3%
Total	145	26	922	84	1177	100%
%	12%	2%	78%	7%	100%	

Tabla A 13. Estadísticos de variables financieras

	Media	Mediana	Desv. Típica	Coefficiente de variación	Mínimo	Máximo	Rango	Amplitud intercuartil	Asimetría	Curtosis
t_vtas	6.330.110	1.963.788	15.344.957	2,4241	0	244.523.984	244.523.984	4.833.941	7,72	85,22
t_vm	6.592.571	1.377.809	20.090.031	3,0474	61	277.060.096	277.060.035	4.277.813	7,56	72,61
a_s_ta	0,9558	0,8001	0,6931	0,7252	0,00	5,03	5,03	0,76	1,88	5,33
a_cf_s	-0,1923	0,0973	9,9244	-51,6056	-336,80	14,08	350,88	0,12	-33,40	1132,25
a_vvtas	0,0073	0,0046	0,2592	35,6535	-1,00	2,48	3,48	0,17	1,61	14,25
f_cf_td	0,1420	0,1227	0,2469	1,7388	-1,20	6,75	7,94	0,13	16,25	436,77
f_ltd_ce	2,3397	0,7555	25,3998	10,8559	-69,27	618,98	688,26	1,05	18,48	395,21
f_fa_ce	2,6937	0,9172	29,2306	10,8514	-55,27	894,15	949,42	1,63	25,84	754,86
f_td_ta	0,6945	0,6574	0,2869	0,4131	-0,66	3,22	3,88	0,23	2,90	18,46
f_dp_e	0,1591	0,0000	3,0070	18,9026	-68,67	57,50	126,17	0,33	-4,36	357,37
f_mve_tl	0,0013	0,0008	0,0021	1,6209	-0,01	0,05	0,05	0,00	9,19	160,30
f_td_ce	4,0454	1,7110	39,2323	9,6980	-96,76	1080,12	1176,87	1,99	20,51	515,40
l_s_wc	-6,1978	4,0055	188,8846	-30,4763	-3932,47	1778,87	5711,33	13,23	-11,68	237,61
l_wc_ltd	2,7395	0,2172	102,4156	37,3851	-2049,45	2489,90	4539,35	0,84	6,61	452,99
l_wc_ta	0,1012	0,0728	0,2291	2,2652	-2,61	0,90	3,51	0,22	-2,15	23,11
l_cl_ta	0,2504	0,2158	0,1889	0,7542	0,01	2,97	2,96	0,17	5,04	51,43
l_quick	1,1992	0,8247	2,5390	2,1173	0,02	57,73	57,71	0,68	15,08	283,72
l_cas_ta	0,2498	0,2142	0,1628	0,6516	0,02	0,94	0,92	0,21	1,20	1,57
l_cas_cl	1,3460	0,9652	2,5797	1,9167	0,05	58,50	58,45	0,75	14,89	278,80
l_ca_cl	1,7983	1,3720	2,6339	1,4647	0,08	58,50	58,42	1,08	13,58	244,97
l_c_cl	0,6247	0,2026	2,5054	4,0106	0,00	56,89	56,89	0,43	15,70	298,53
l_i_tca	0,2562	0,2207	0,2126	0,8298	-0,20	0,98	1,18	0,33	0,73	-0,09
l_ca_ta	0,3515	0,3303	0,2055	0,5847	0,02	0,98	0,96	0,31	0,55	-0,33
l_cl_tl	0,3710	0,3350	0,2011	0,5420	-0,27	1,17	1,44	0,28	0,76	0,43
g_ebit_i	0,3782	0,8763	28,0705	74,2261	-862,26	128,53	990,78	3,49	-25,15	769,95
g_nia_ta	0,0453	0,0621	0,2791	6,1650	-1,69	6,99	8,68	0,09	13,05	336,22
g_ebit_s	-0,5976	0,0268	17,1121	-28,6351	-581,95	13,54	595,49	0,09	-33,61	1141,52
g_ronfa	0,0502	0,0534	2,7870	55,5383	-37,05	61,24	98,29	0,26	7,99	235,27
g_ebit_a	-0,0046	0,0240	0,2760	-60,5609	-1,74	6,71	8,45	0,07	11,78	308,68
g_roe	1,4046	0,0898	52,2290	37,1831	-144,57	1781,83	1926,40	0,19	33,81	1154,14
g_re_ta	-0,0458	0,1137	1,1391	-24,8539	-20,95	2,54	23,50	0,31	-11,44	172,35
v_vol250	58,1245	44,5750	43,3470	0,7458	0,00	551,18	551,18	31,61	4,14	29,84

Nota: los valores ennegrecidos son cifras que sobrepasan los límites comunes de este tipo de estadísticos, teniendo en cuenta la interpretación financiera que se hace de ellos.

Tabla A 14. Matriz de Correlaciones Tau-b de Kendall para las variables cuantitativas de la muestra

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_tl	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,61	0,16	0,02	0,07	0,13	-0	0,07	-0	0,2	0,1	0,11	0,04	-0	-0,1	0,23	-0,2	0,02	-0,2	-0,2	-0,1	0,11	0,03	0,25	0,21	0,1	0,11	0,15	0,16	0,12	0,24	-0,2	
t_vm		1	-0,1	0,26	0,08	0,28	-0,1	0,04	-0,2	0,26	0,39	-0	-0	-0	-0,1	0,04	-0,1	-0	-0,1	-0	-0	-0,1	-0,1	0,16	0,32	0,18	0,28	0,23	0,27	0,12	0,32	-0,4	
a_s_ta			1	-0,4	0,1	0,12	-0,1	-0,1	0,05	0	0,05	0,02	0,2	0,18	0,18	0,41	-0,1	0,23	-0,1	0,09	-0,1	0,35	0,4	0,36	0,17	0,22	-0	0,2	0,19	0,15	0,14	-0	
a_cf_s				1	0,05	0,47	0,03	0,13	-0,2	0,18	0,24	-0	-0,1	-0,2	-0,2	-0,3	-0	-0,2	0,01	-0,1	-0	-0,2	-0,3	-0,2	0,26	0,25	0,47	0,21	0,28	0,1	0,18	-0,3	
a_vvtas					1	0,15	-0	-0	-0	0,01	0,1	-0	0,02	0,01	0,01	-0	-0	-0,1	-0	0,01	-0	0,07	-0	0,02	0,17	0,2	0,13	0,2	0,18	0,12	0,05	-0,1	
f_cf_td						1	-0,2	-0	-0,4	0,19	0,51	-0,2	0,03	0,1	0,07	-0,1	0,06	-0	0,07	0,07	0,02	0,03	-0	0,13	0,52	0,48	0,46	0,43	0,53	0,23	0,39	-0,3	
f_ltd_ce							1	0,55	0,38	0,03	-0,3	0,73	0	-0,2	-0,1	-0,1	-0,1	-0,2	-0,1	-0,1	-0,1	0,03	-0,2	-0,2	-0,1	-0	0,01	-0	-0	-0,1	-0,1	-0	
f_fa_ce								1	0,2	0,13	-0,2	0,55	0	-0,3	-0,3	-0,1	-0,2	-0,3	-0,2	-0,3	-0,2	-0,3	-0,2	-0,2	-0	0	0,07	-0,1	0	-0,1	-0	-0,2	
f_td_ta									1	-0,1	-0,5	0,6	-0	-0,3	-0,3	0,22	-0,3	-0,1	-0,3	-0,3	-0,2	-0	-0,1	-0,1	-0,2	-0,1	-0,2	-0,2	-0,2	0,1	-0,3	0,11	
f_dp_e										1	0,15	0,07	0,03	-0,1	-0,1	0,02	-0,1	-0,1	-0,1	-0,1	-0,1	0,07	-0,1	0,05	0,33	0,24	0,33	0,25	0,28	0,19	0,24	-0,4	
f_mve_tl											1	-0,3	0,02	0,22	0,18	-0,1	0,18	0,12	0,18	0,19	0,15	-0	0,11	0,17	0,42	0,33	0,34	0,34	0,41	0,13	0,37	-0,3	
f_td_ce												1	0,03	-0,2	-0,2	0,09	-0,2	-0,1	-0,2	-0,2	-0,2	0,07	-0,1	-0,1	-0,1	0,01	-0	0,01	-0	-0,1	-0,1	-0,1	
l_s_wc													1	0,12	0,05	0,04	0,03	0,04	0,02	-0	-0	0,15	0,09	0,02	0,04	0,06	-0	0,05	0,05	0	0,08	-0	
l_wc_ltd														1	0,82	-0	0,48	0,4	0,49	0,7	0,32	0,18	0,52	0,16	0,07	0,03	-0	0,11	0,06	-0,1	0,15	0,09	
l_wc_ta															1	-0,1	0,54	0,42	0,54	0,81	0,34	0,17	0,55	0,07	0,03	0,03	-0	0,1	0,04	-0,1	0,11	0,13	
l_cl_ta																1	-0,2	0,34	-0,2	-0,2	-0,1	0,13	0,39	0,65	0,06	0,03	-0,1	0,08	0,03	0,15	0,01	0,03	
l_quick																	1	0,41	0,87	0,62	0,52	-0,2	0,26	-0,1	-0	-0,1	-0	0,01	-0	-0,1	0,02	0,13	
l_cas_ta																		1	0,42	0,33	0,32	-0,1	0,67	0,37	-0	-0	-0,1	0,05	-0	-0	0,01	0,16	
l_cas_cl																			1	0,64	0,5	-0,2	0,26	-0,1	-0	-0,1	-0	-0	-0	-0,1	0,02	0,14	
l_ca_cl																				1	0,38	0,14	0,42	-0	0,02	0,02	-0	0,08	0,03	-0,1	0,09	0,14	
l_c_cl																					1	-0,2	0,21	-0	-0	-0,1	-0,1	-0	-0,1	-0,1	-0	0,17	
l_i_tca																						1	0,2	0,12	0,1	0,14	0,02	0,13	0,12	0,04	0,17	-0,1	
l_ca_ta																							1	0,43	0,05	0,03	-0,1	0,13	0,04	0,03	0,07	0,14	
l_cl_tl																								1	0,17	0,08	-0	0,16	0,12	0,09	0,16	-0	
g_ebit_i																									1	0,67	0,68	0,73	0,8	0,47	0,44	-0,4	
g_nia_ta																										1	0,63	0,69	0,81	0,51	0,36	-0,3	
g_ebit_s																											1	0,64	0,74	0,44	0,36	-0,4	
g_ronfa																												1	0,78	0,47	0,38	-0,3	
g_ebit_a																													1	0,56	0,43	-0,4	
g_roe																														1	0,16	-0,2	
g_re_ta																															1	-0,4	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal.

C.5. Acerca de la exploración global de los datos

Tabla A 15. Test estadísticos de normalidad de las variables cuantitativas

	Kolmogorov-Smirnov ^a		
	Estadístico	gl	Sig.
t_vtas2	,340	1177	,000
t_vm2	,371	1163	,000
a_s_ta	,111	1177	,000
a_cf_s	,479	1173	,000
a_vvtas	,150	1173	,000
a_cf_td	,199	1177	,000
f_ltd_ce	,409	1175	,000
f_fa_ce	,424	1172	,000
f_td_ta	,137	1177	,000
f_dp_e	,392	1173	,000
f_mve_tl	,268	1167	,000
f_td_ce	,397	1175	,000
l_s_wc	,372	1167	,000
l_wc_ltd	,468	1153	,000
l_wc_ta	,132	1167	,000
l_cl_ta	,127	1167	,000
l_quick	,325	1161	,000
l_cas_ta	,092	1154	,000
l_cas_cl	,310	1154	,000
l_ca_cl	,271	1167	,000
l_c_cl	,402	1166	,000
l_i_tca	,113	1154	,000
l_ca_ta	,062	1167	,000
l_cl_tl	,073	1167	,000
g_ebit_i	,334	1168	,000
g_nia_ta	,259	1173	,000
g_ebit_s	,468	1171	,000
g_ronfa	,349	1169	,000
g_ebit_a	,287	1175	,000
g_roe	,469	1174	,000
g_re_ta	,287	1157	,000
v_vol250	,185	1152	,000

Nota (a) El test Kolmogorov-Smirnov utilizado tiene la corrección de la significación de Lilliefors. Esta prueba se utiliza para contrastar la normalidad de las distribuciones de los datos (Visauta, 1998). En ninguna de ellas el test supera el 1% de significatividad, por lo que ninguna de las variables tiene una distribución normal, asumiendo un 1% de error

Figura A 2. Histogramas variables Tamaño sin agrupar datos

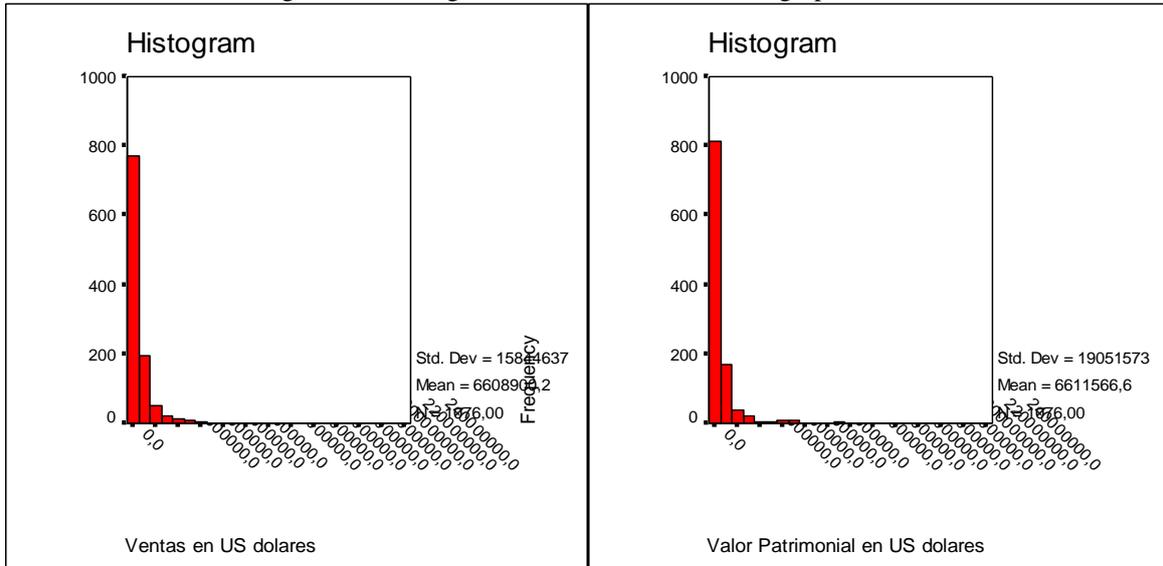


Figura A 3. Histogramas de las variables de actividad sin agrupar datos

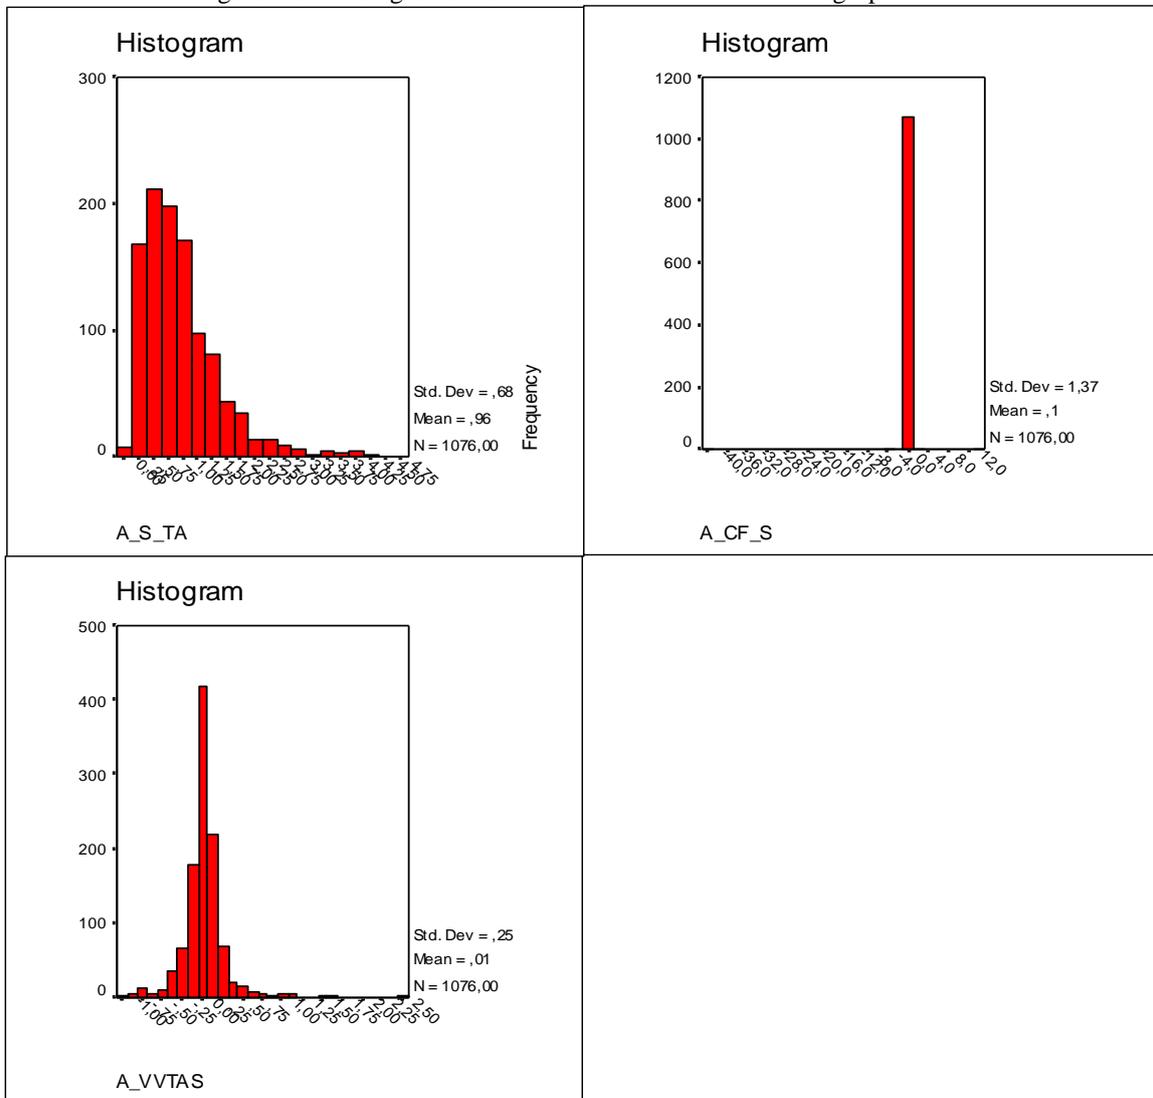


Figura A 4. Histogramas de las variables de financiamiento sin agrupar datos

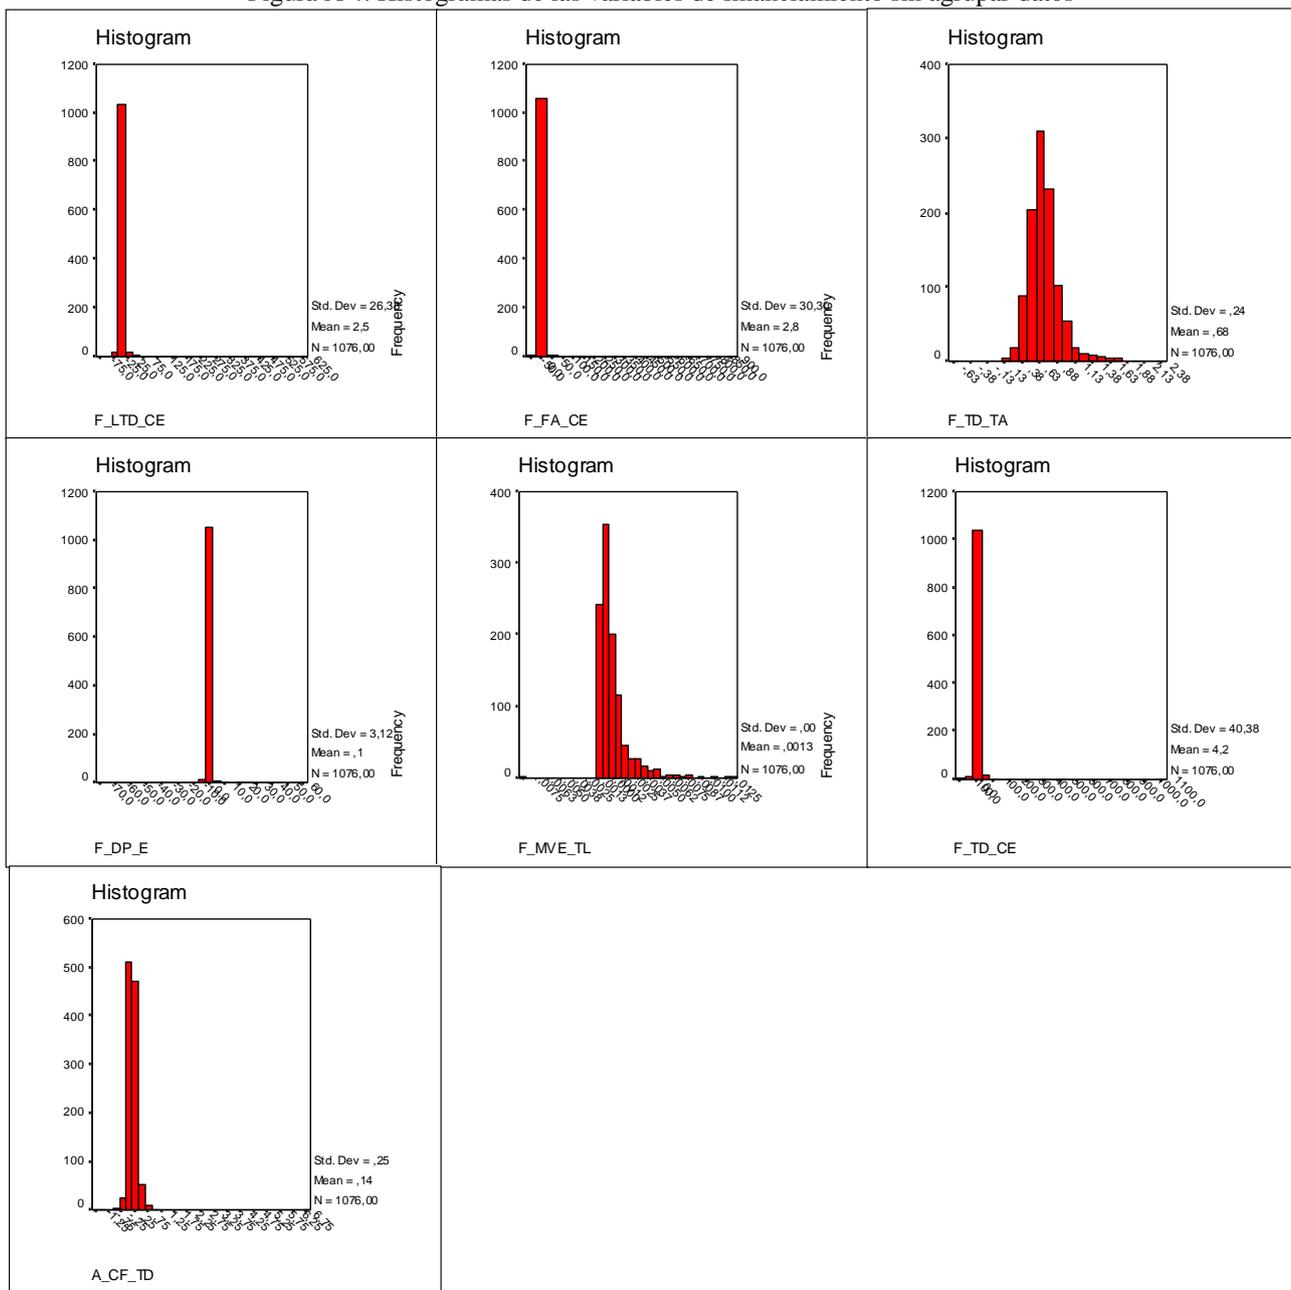


Figura A 5. Histogramas de las variables de liquidez sin agrupar datos

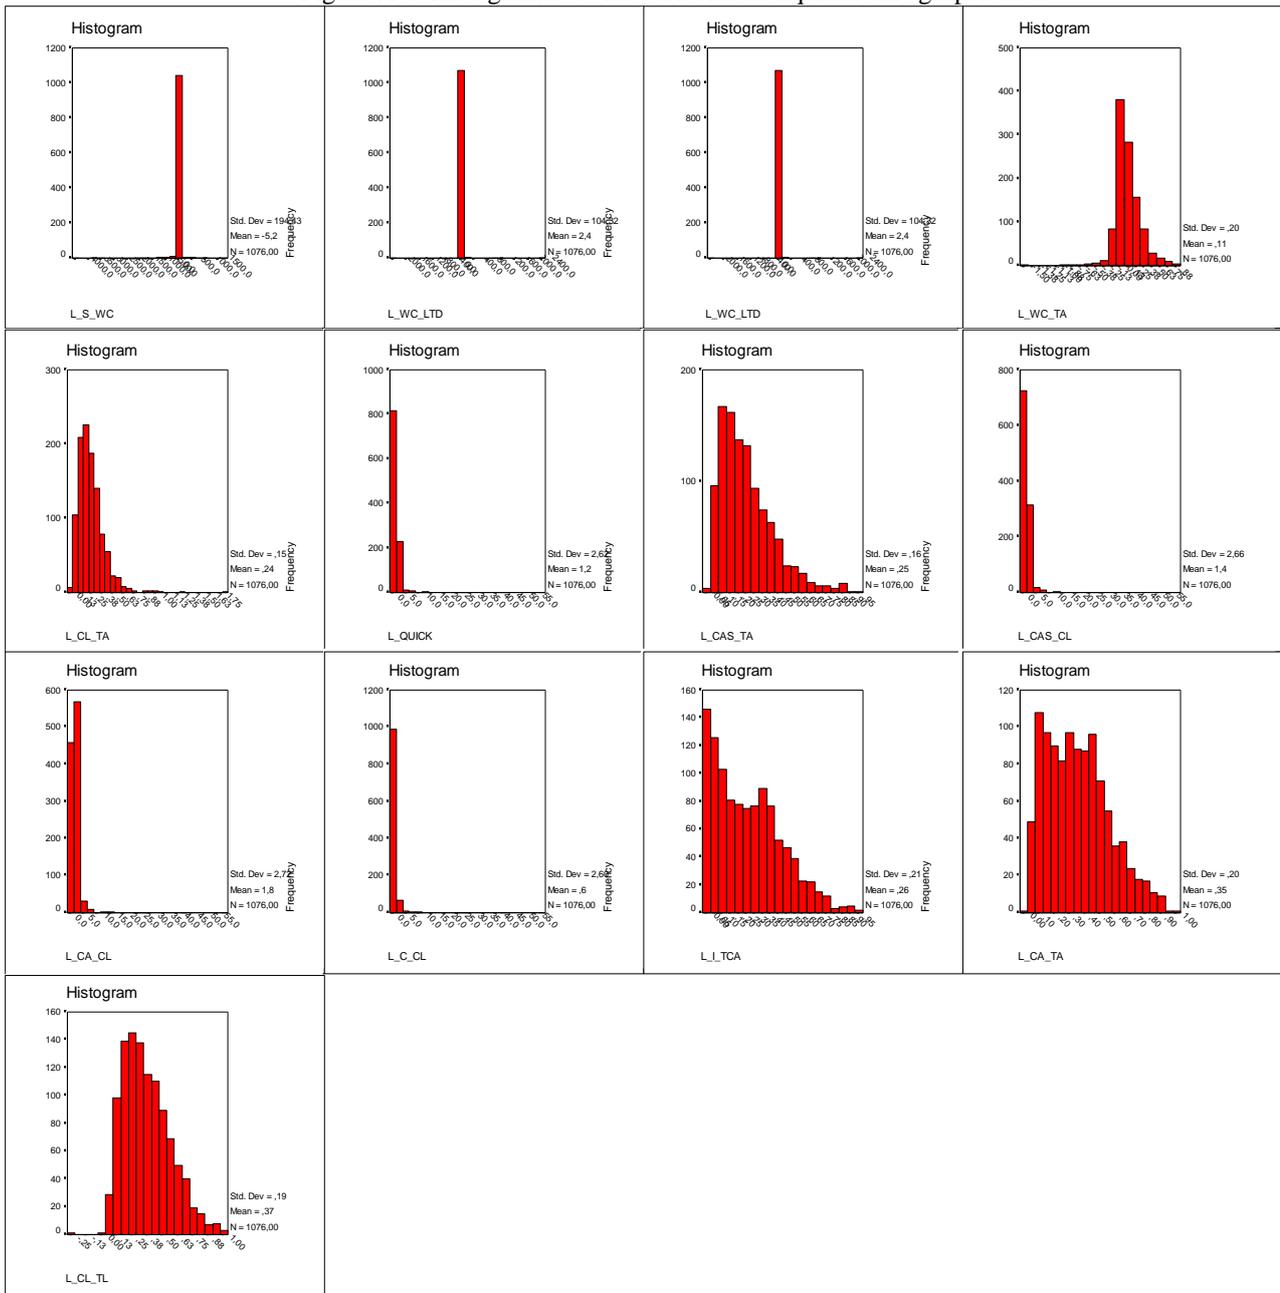


Figura A 6. Histograma de la variable de volatilidad sin agrupar datos

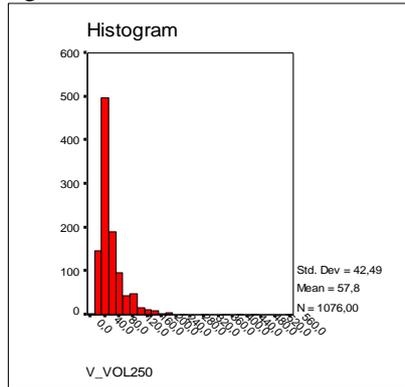


Figura A 7. Histogramas de las variables de rentabilidad sin agrupar datos

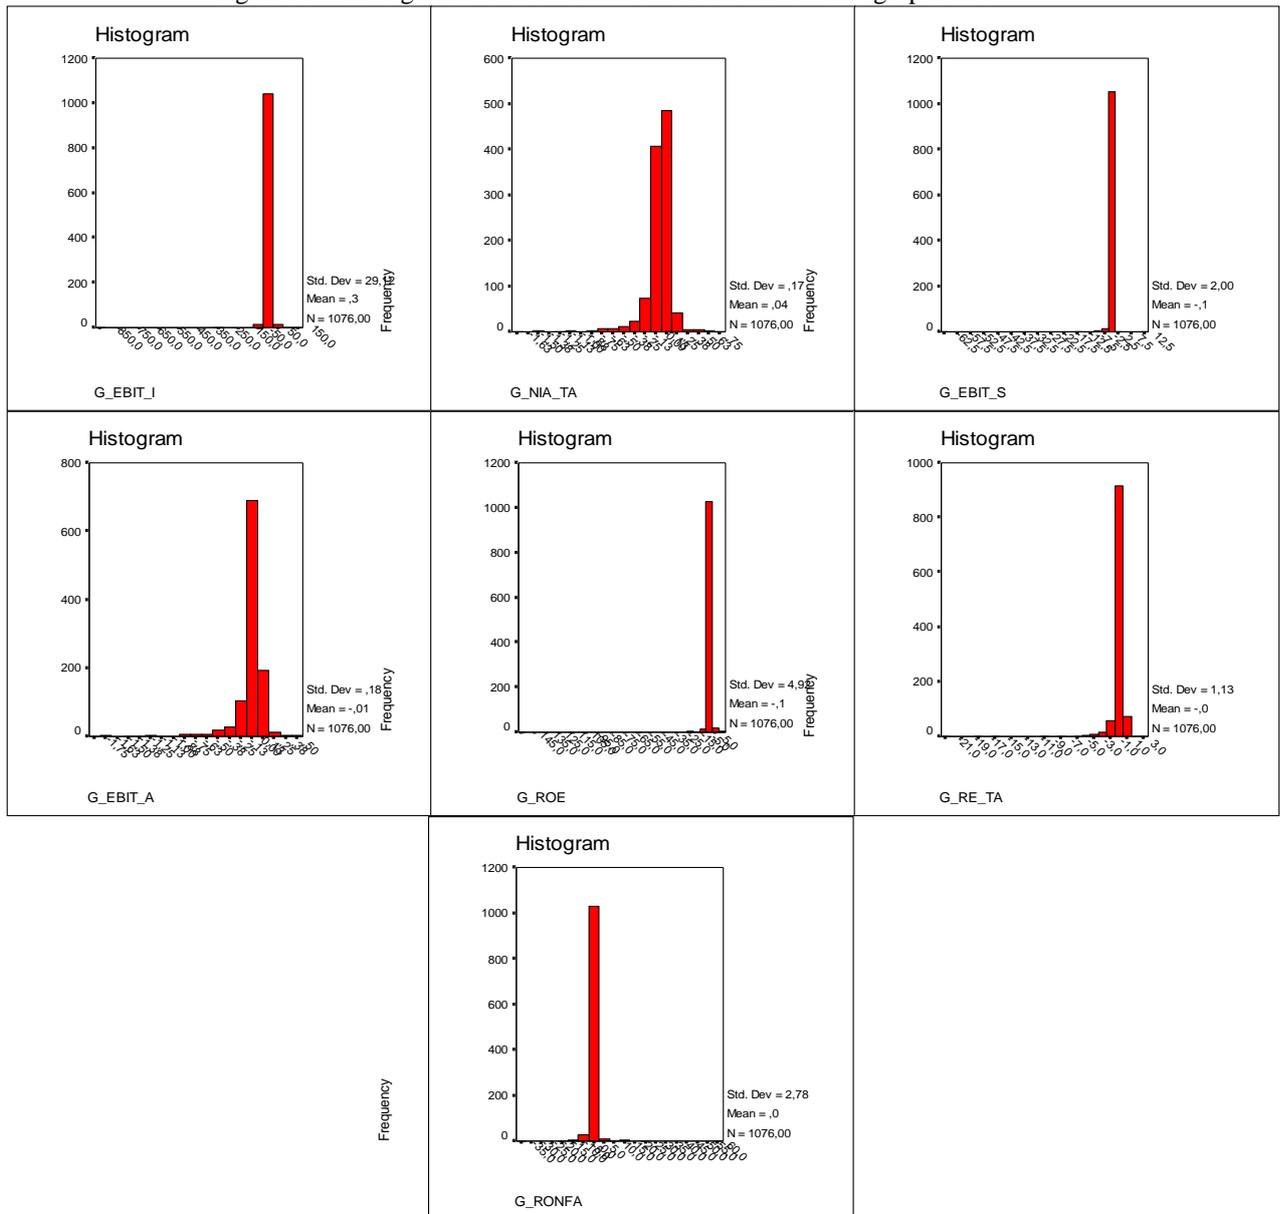


Figura A 8. Diagramas de caja de las variables de tamaño sin agrupar datos

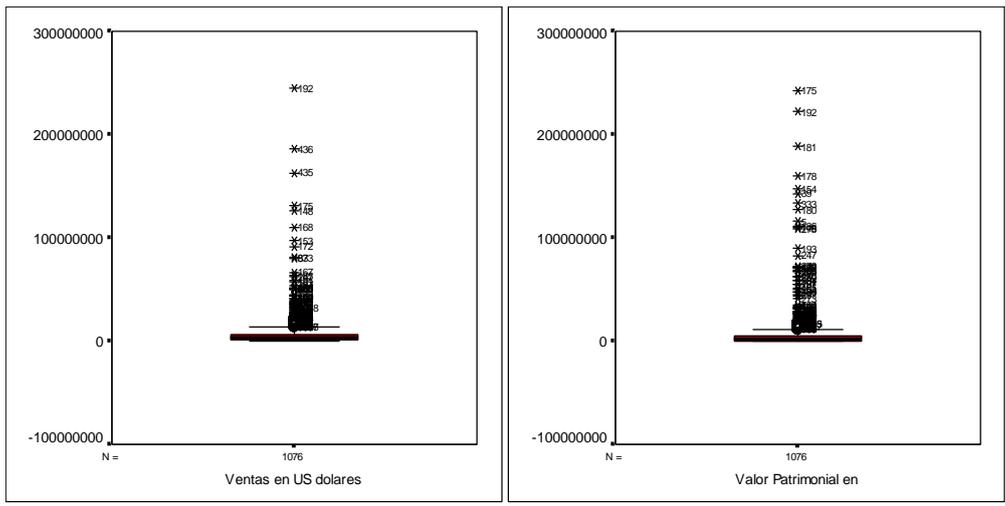


Figura A 9. Diagrama de caja de la variable de volatilidad sin agrupar sin agrupar datos

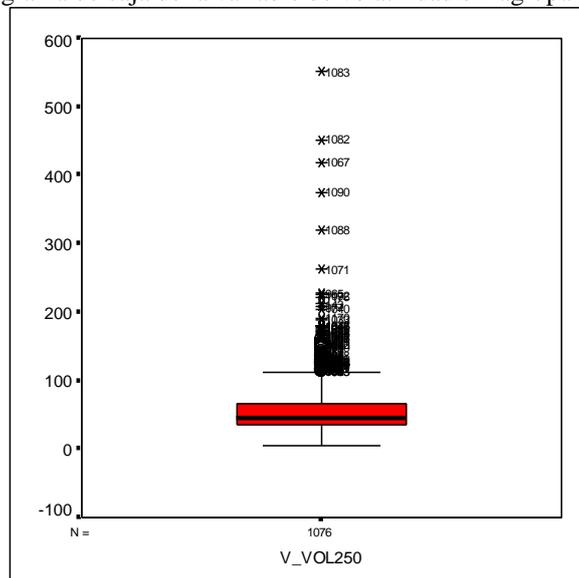


Figura A 10. Diagramas de caja de las variables de actividad sin agrupar datos

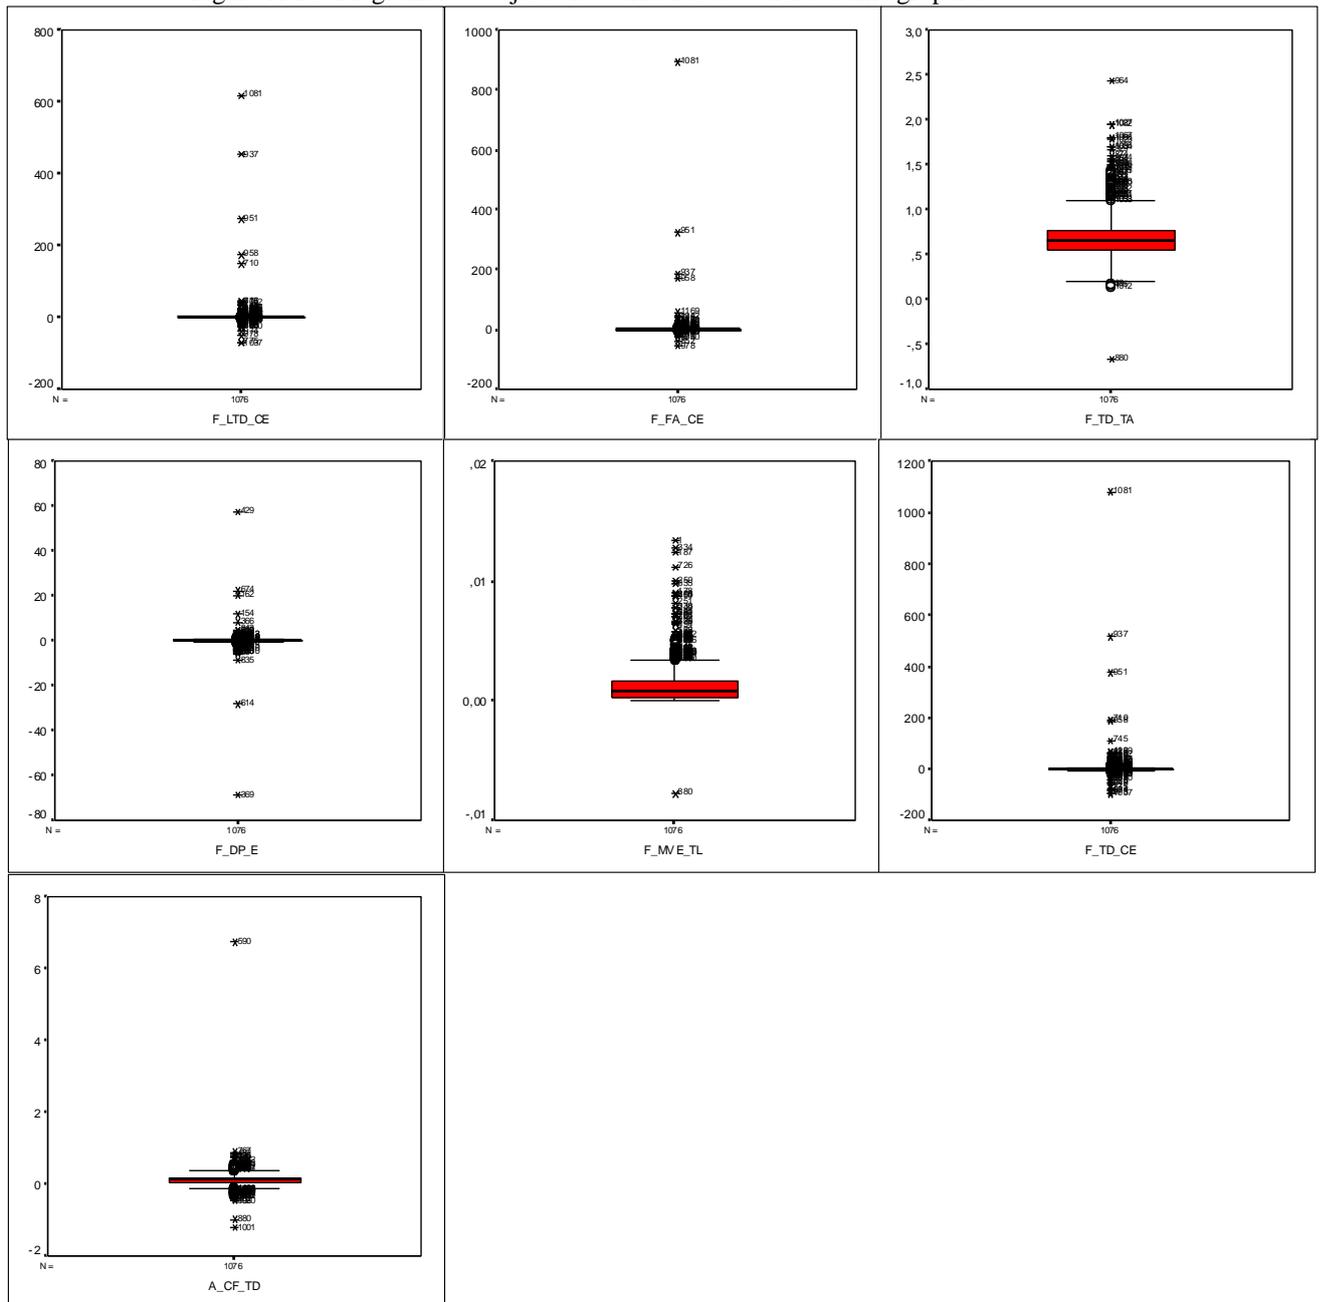


Figura A 11. Diagrama de cajas variables financiamiento sin agrupar datos

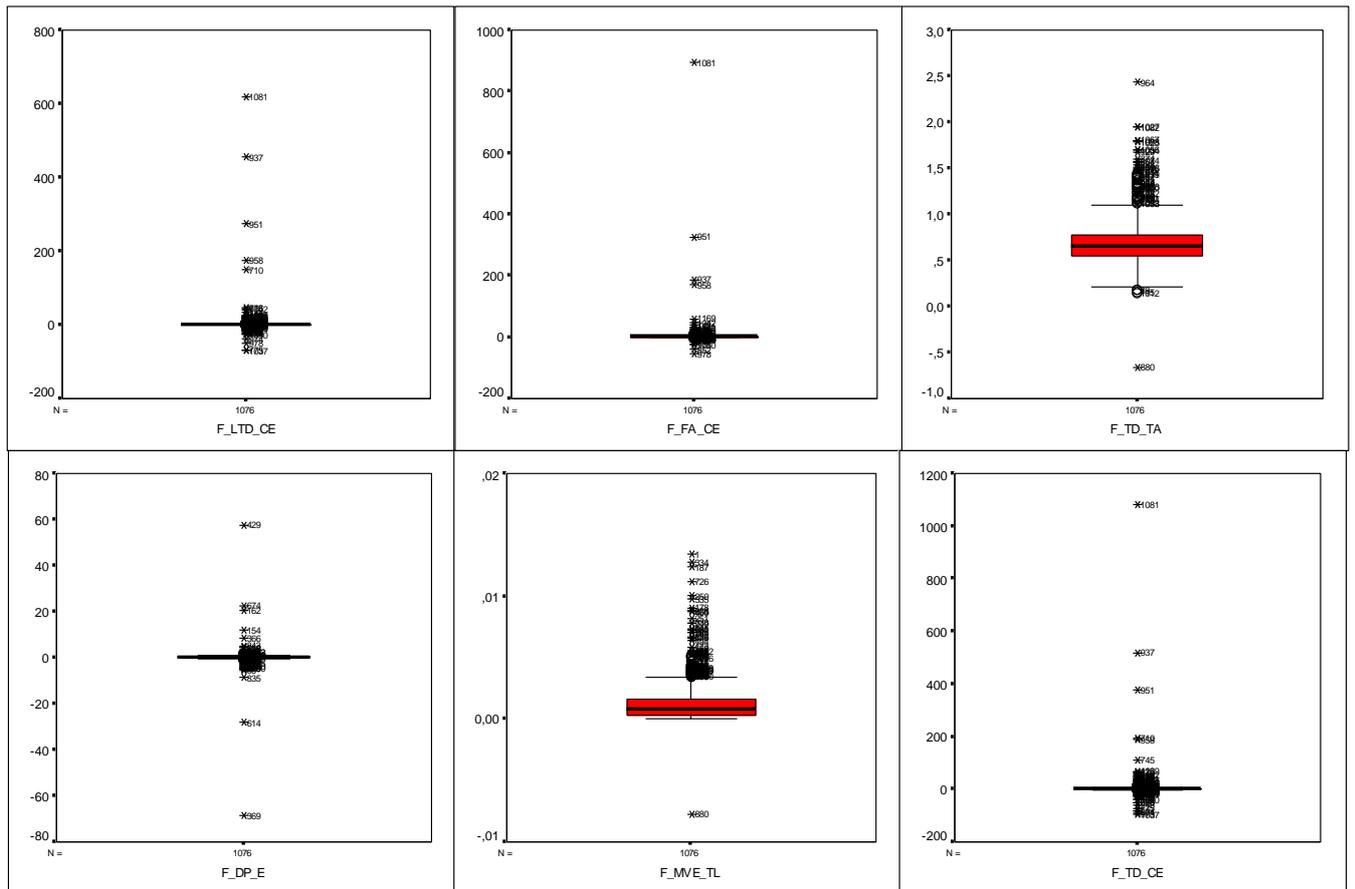
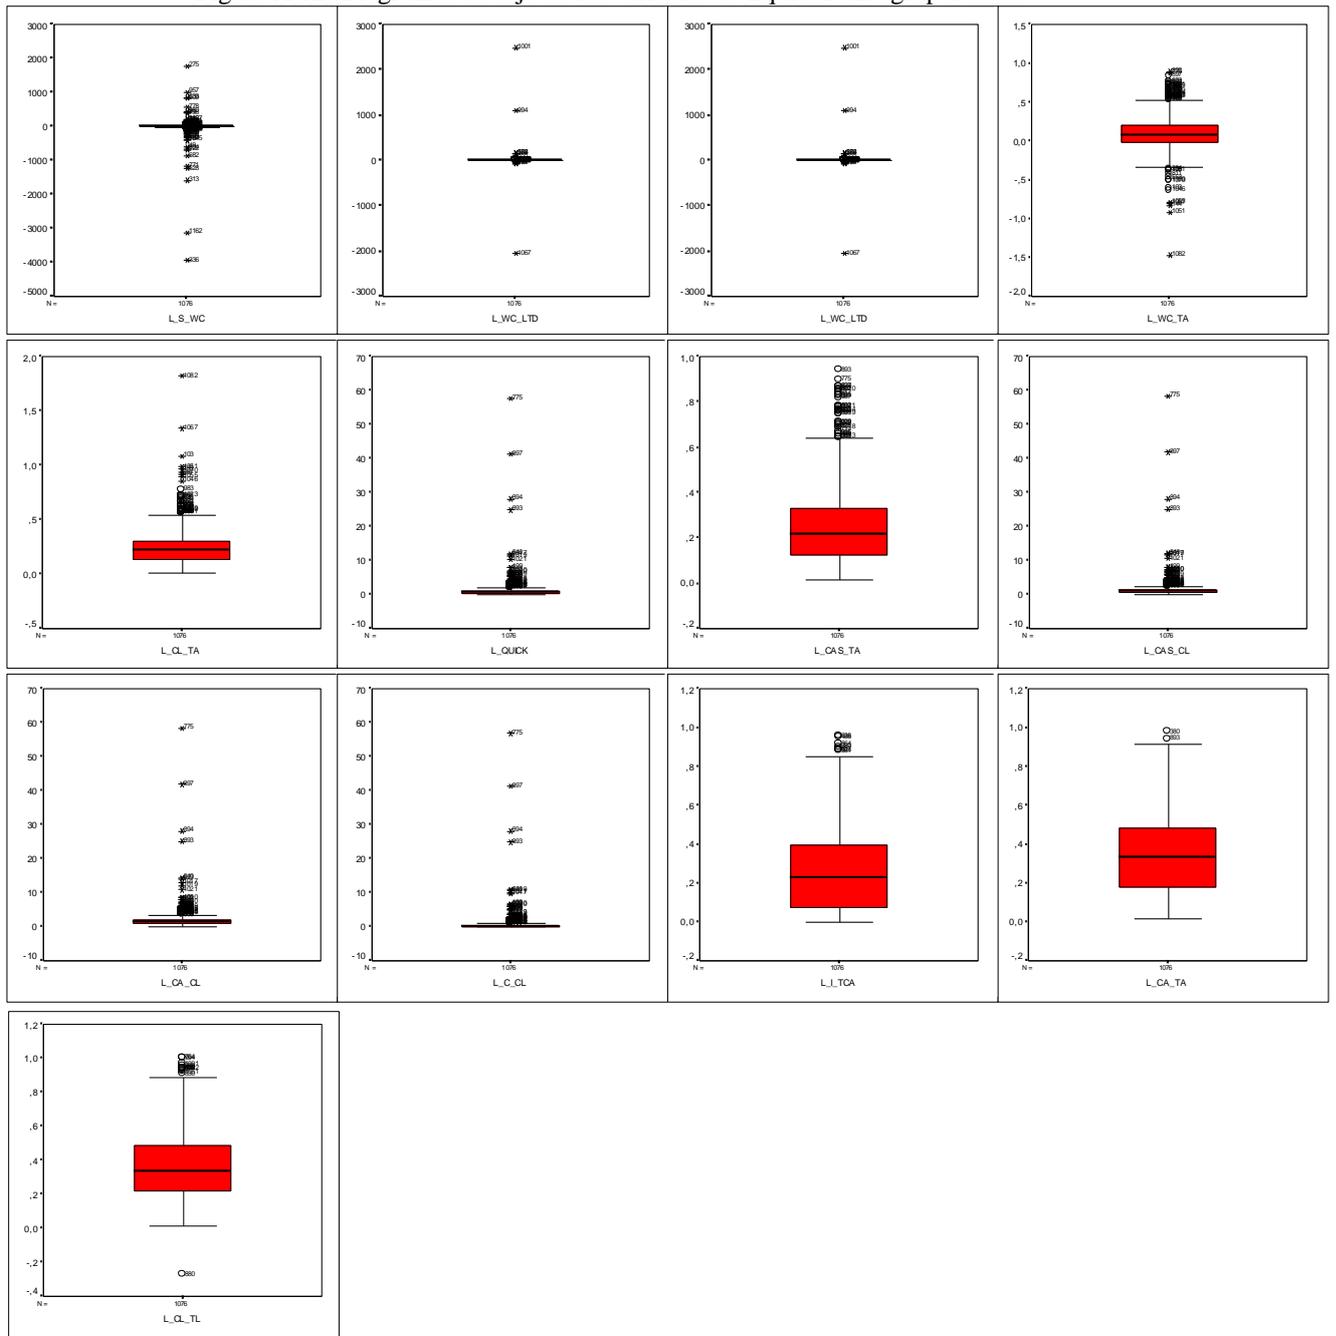


Figura A 12. Diagramas de caja de las variables de liquidez sin agrupar datos



C.6. Acerca de la muestra agrupada por rating

Tabla A 17. Medianas de las variables cuantitativas respecto del rating

	AA-AAA	A	BBB	BB	B	C	D
t_vtas	16.833.534	5.384.425	3.108.686	1.229.825	546.547	272.116	666.911
t_vm	24.219.048	6.747.340	2.401.603	681.470	276.058	40.866	32.920
	AA-AAA	A	BBB	BB	B	C	D
a_cf-s	0,18	0,13	0,10	0,09	0,06	0,02	0,01
a_s-ta	0,84	0,79	0,85	0,86	0,72	0,62	1,09
a_vvtas	0,02	0,00	0,00	0,01	0,00	0,02	-0,10
	AA-AAA	A	BBB	BB	B	C	D
f_cf-td	0,24	0,17	0,13	0,11	0,07	0,02	0,01
f_ltd-ce	0,38	0,58	0,81	0,98	0,83	-0,96	0,00
f_fa-ce	1,01	0,99	1,19	0,95	0,49	-0,38	-0,52
f_td-ta	0,58	0,61	0,65	0,66	0,73	1,01	1,05
f_mve-tl	0,00	0,00	0,00	0,00	0,00	0,00	0,00
f_dp-e	0,40	0,33	0,16	0,00	0,00	0,00	0,00
f_td-ce	1,45	1,67	1,86	1,93	1,43	-2,28	-1,73
	AA-AAA	A	BBB	BB	B	C	D
l_s-wc	5,09	4,01	4,23	4,77	3,47	2,39	4,26
l_ca-cl	1,19	1,26	1,22	1,62	1,78	1,27	1,25
l_cas-cl	0,93	0,89	0,89	1,01	1,30	0,97	0,77
l_quick	0,83	0,76	0,77	0,85	1,12	0,82	0,71
l_cl-tl	0,49	0,40	0,37	0,30	0,26	0,26	0,40
l_c-cl	0,25	0,19	0,14	0,22	0,47	0,26	0,14
l_ca-ta	0,33	0,32	0,30	0,34	0,42	0,31	0,37
l_wc-ltd	0,17	0,26	0,18	0,30	0,31	0,09	0,10
l_i-tca	0,19	0,23	0,26	0,29	0,13	0,05	0,22
l_cl-ta	0,26	0,24	0,22	0,19	0,19	0,28	0,28
l_cas-ta	0,24	0,22	0,20	0,20	0,27	0,23	0,22
l_wc-ta	0,04	0,05	0,05	0,12	0,16	0,05	0,06
	AA-AAA	A	BBB	BB	B	C	D
g_nia-ta	0,12	0,08	0,07	0,05	0,02	-0,08	-0,05
g_ebit-a	0,07	0,04	0,03	0,01	-0,04	-0,18	-0,13
g_ebit-s	0,08	0,06	0,04	0,01	-0,06	-0,27	-0,13
g_ronfa	0,15	0,11	0,08	0,04	-0,11	-0,41	-0,20
g_roe	0,18	0,12	0,10	0,05	-0,02	0,59	0,35
g_re-ta	0,35	0,27	0,17	0,11	-0,13	-0,74	-0,22
g_ebit-i	7,67	2,53	1,51	0,49	-0,81	-3,67	-1,72
	AA-AAA	A	BBB	BB	B	C	D
v_vol250	30,40	34,86	39,02	50,45	77,83	121,86	179,43

Figura A 14. Gráficos de barra de medianas de las variables de la muestra agrupadas por rating



Nota: Las gráficas presentadas en esta figura tienen distintas escalas, motivo por el cual las variables f_{mve-tl} y g_{ebit-i} han sido reproducidas por separado y cambiando la escala para observar su tendencia.

Figura A 15. Gráficos de barra de medianas de la variable a_vvtas agrupadas por rating y por sector industrial

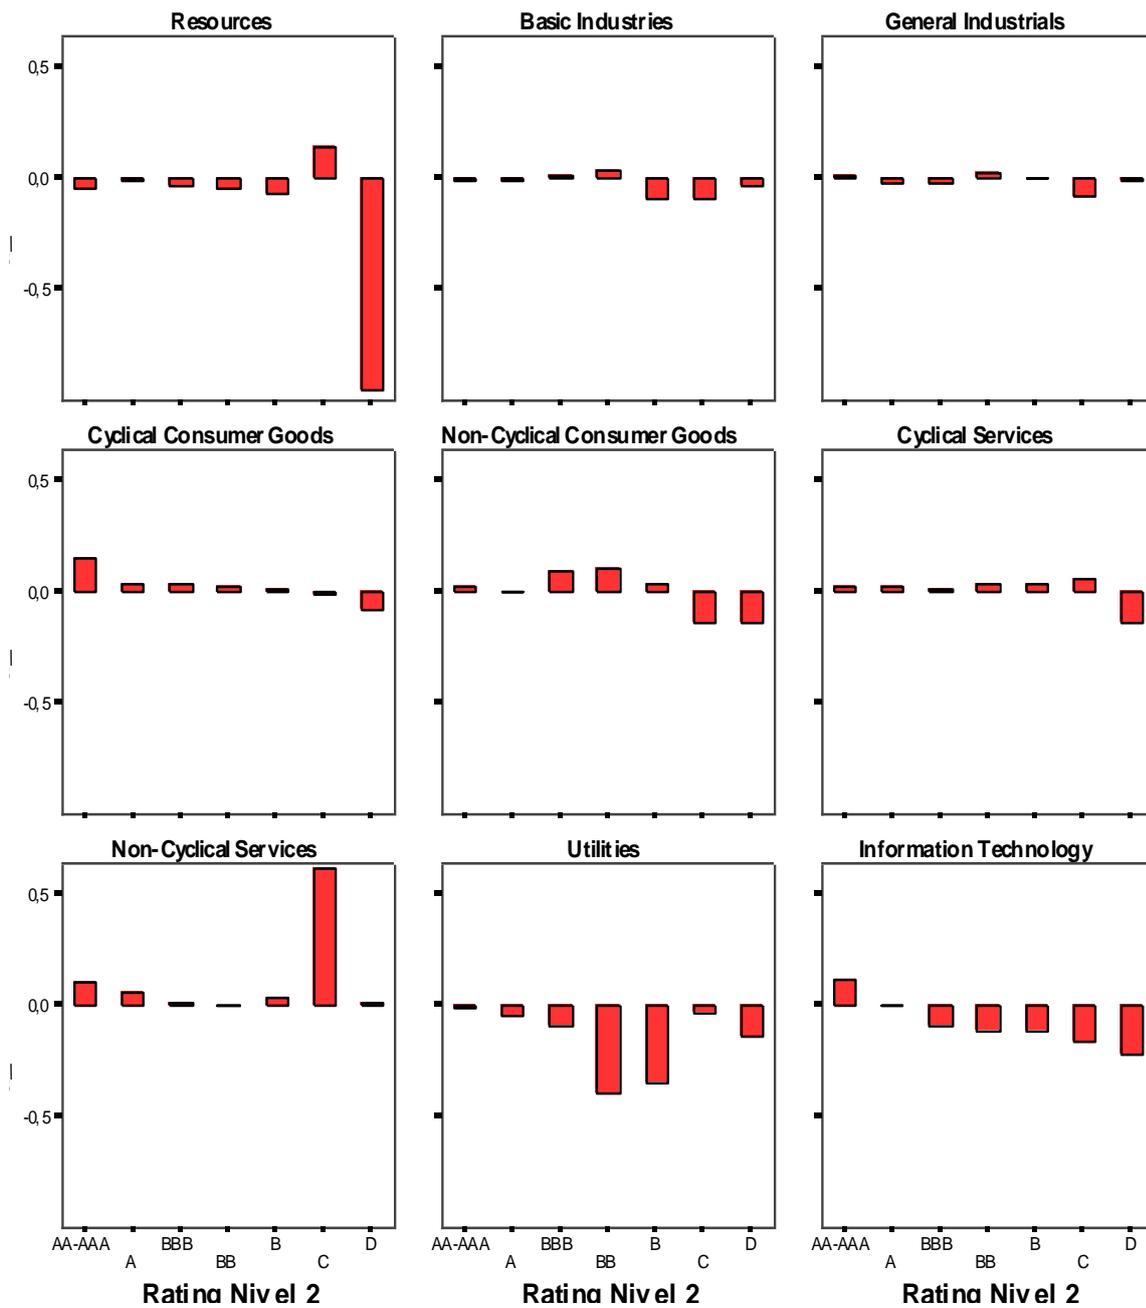


Figura A 16. Gráficos de barra de medianas, de la variable l_s-wc, agrupadas por rating y por sector industrial

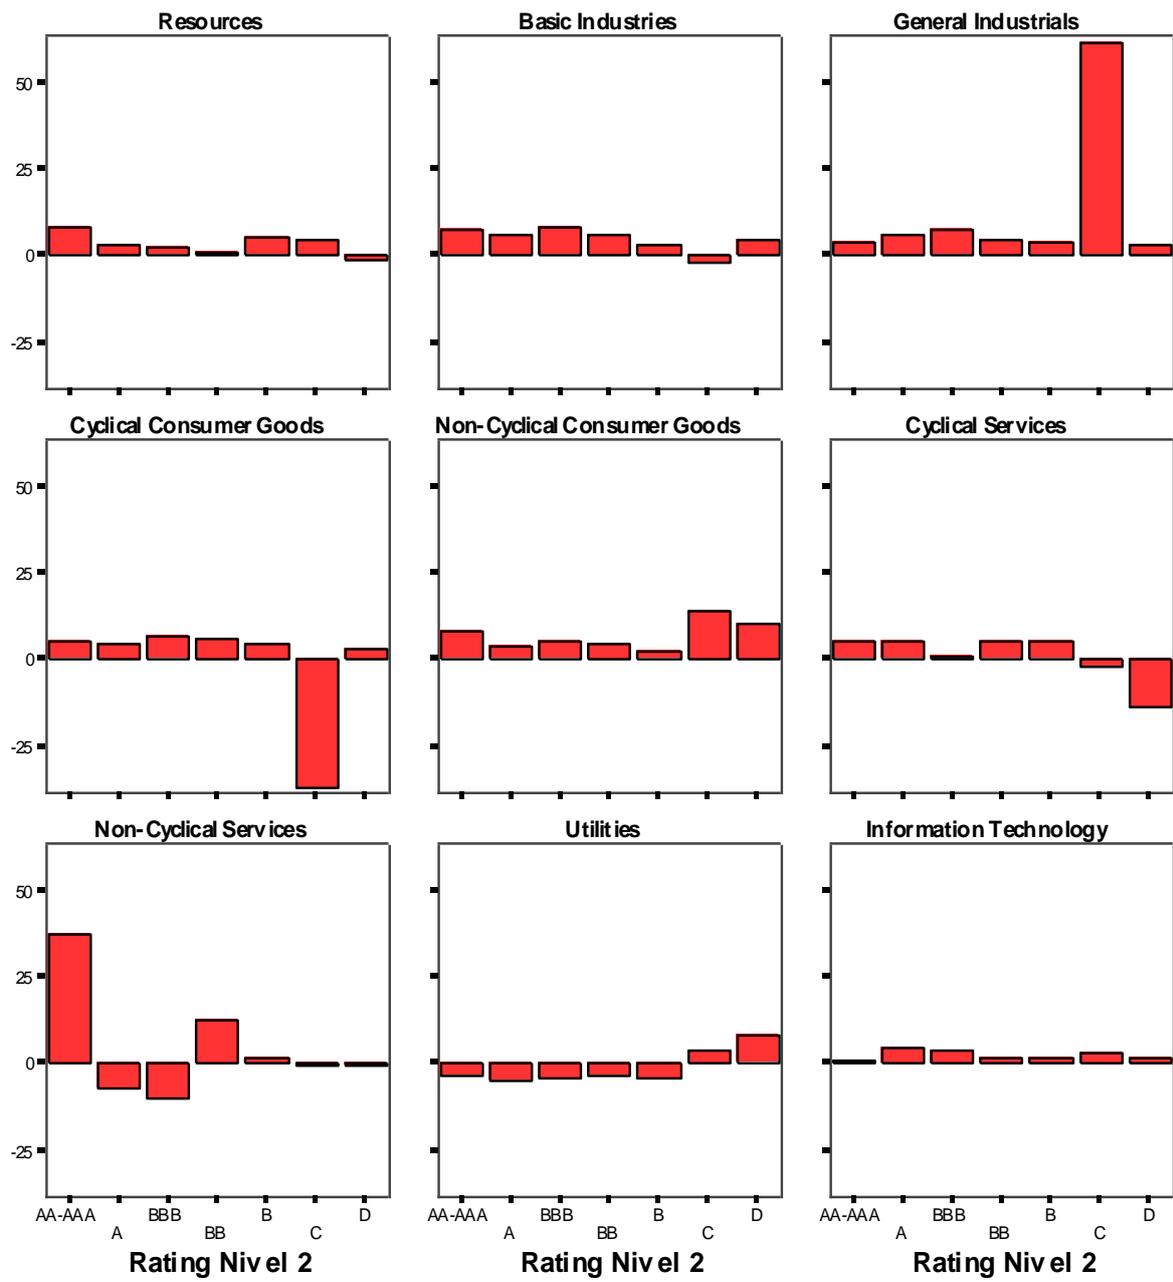
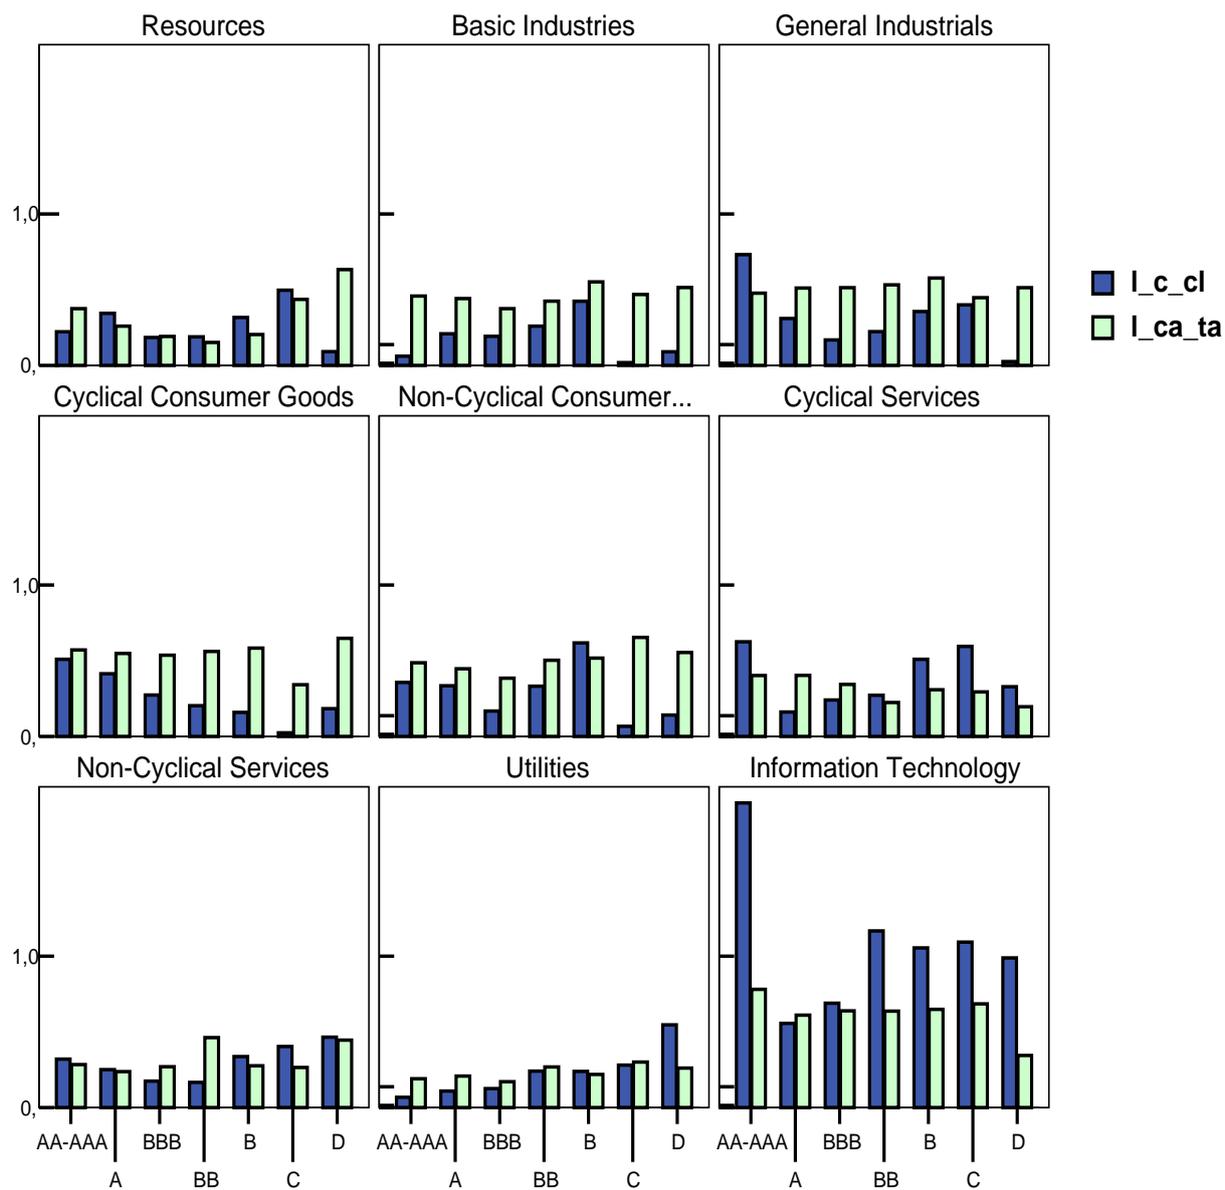


Figura A 17. Gráficos de barra de medianas del logaritmo de las variables l_c-cl y l_ca-ta agrupadas por rating y por sector industrial



NOTA: en este caso se ha elegido calcular la mediana del logaritmo de los datos debido a que en el sector "Information Technology" las medianas son bastante más altas que en los otros sectores industriales.

Figura A 18. Gráficos de barra de medianas de las variables l_cl-ta y l_cas-ta agrupadas por rating y por sector industrial

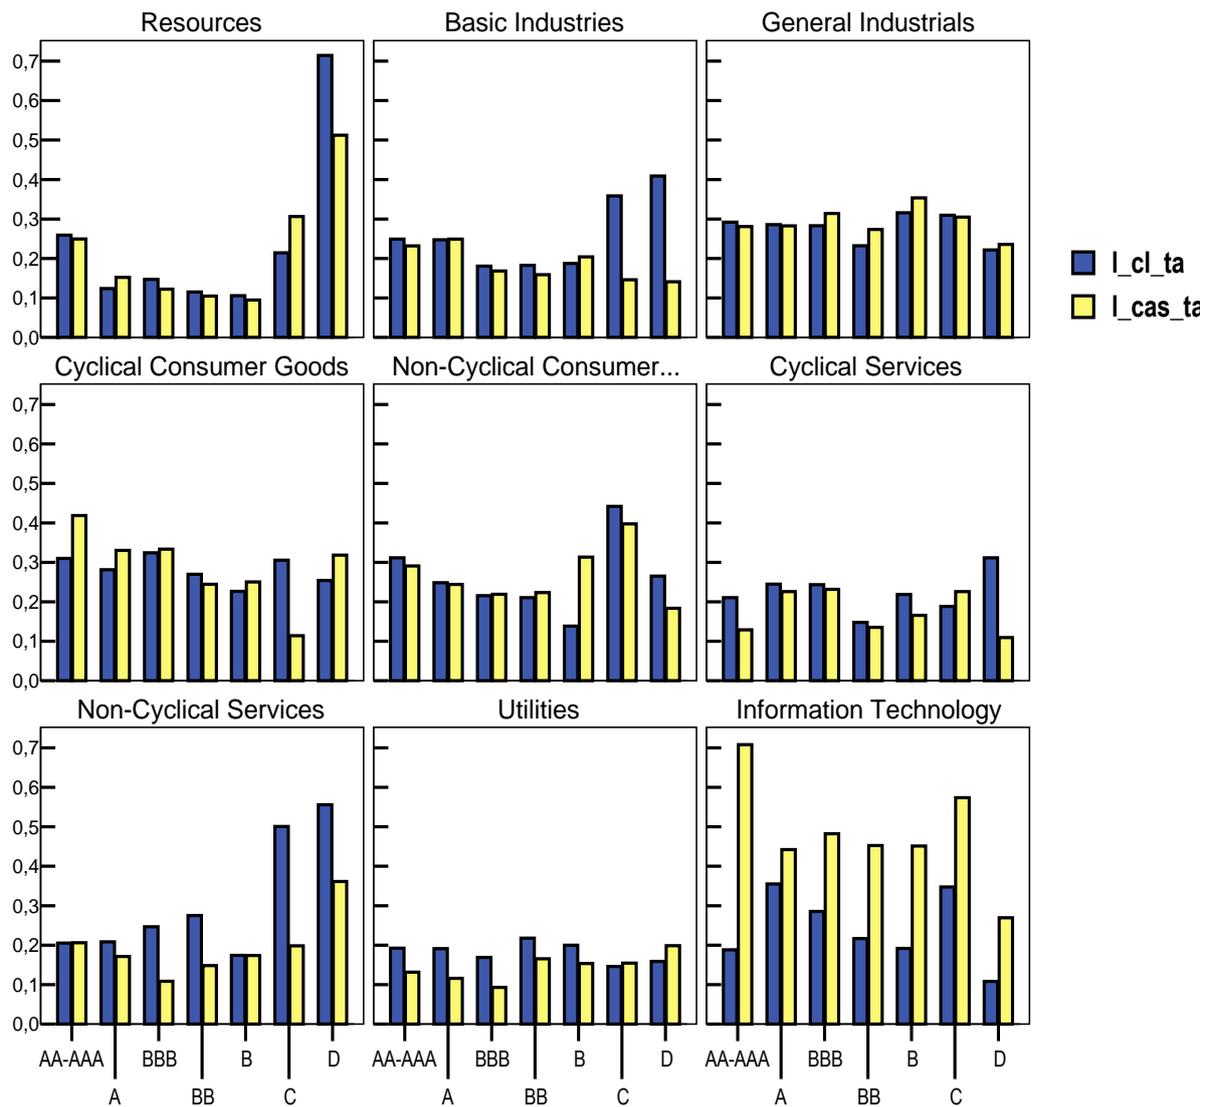


Figura A 19. Gráficos de barra de medianas de la raíz cúbica de la variable I_{wc_ltd} agrupada por rating y por sector industrial

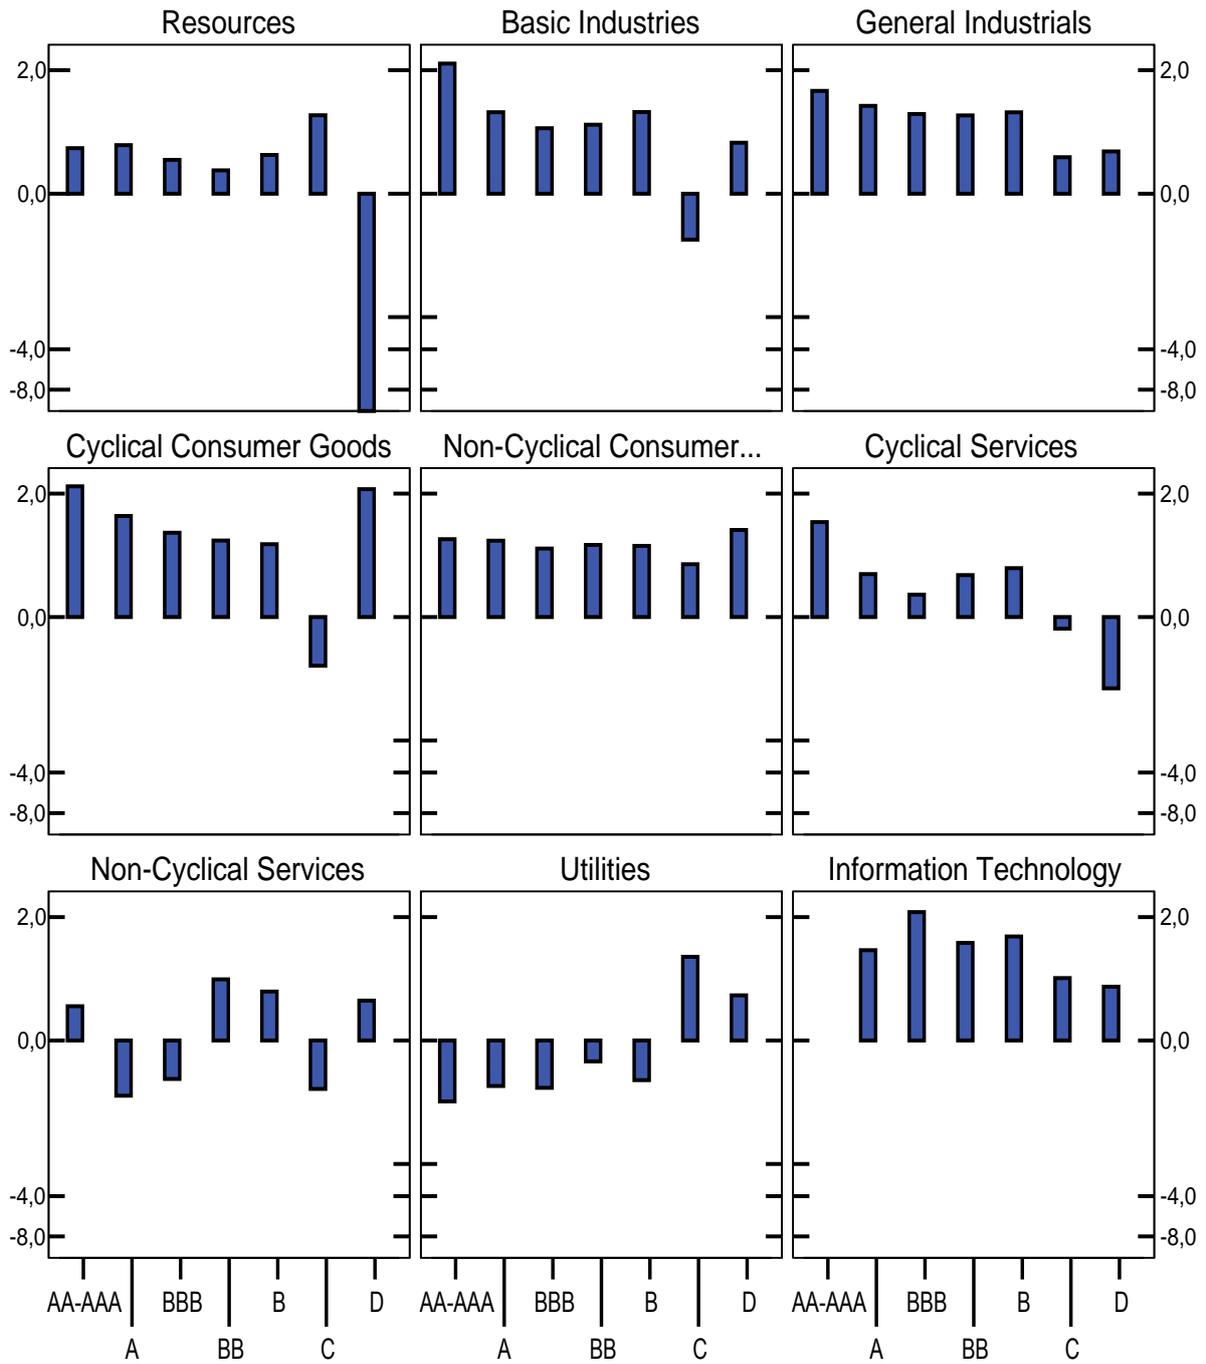
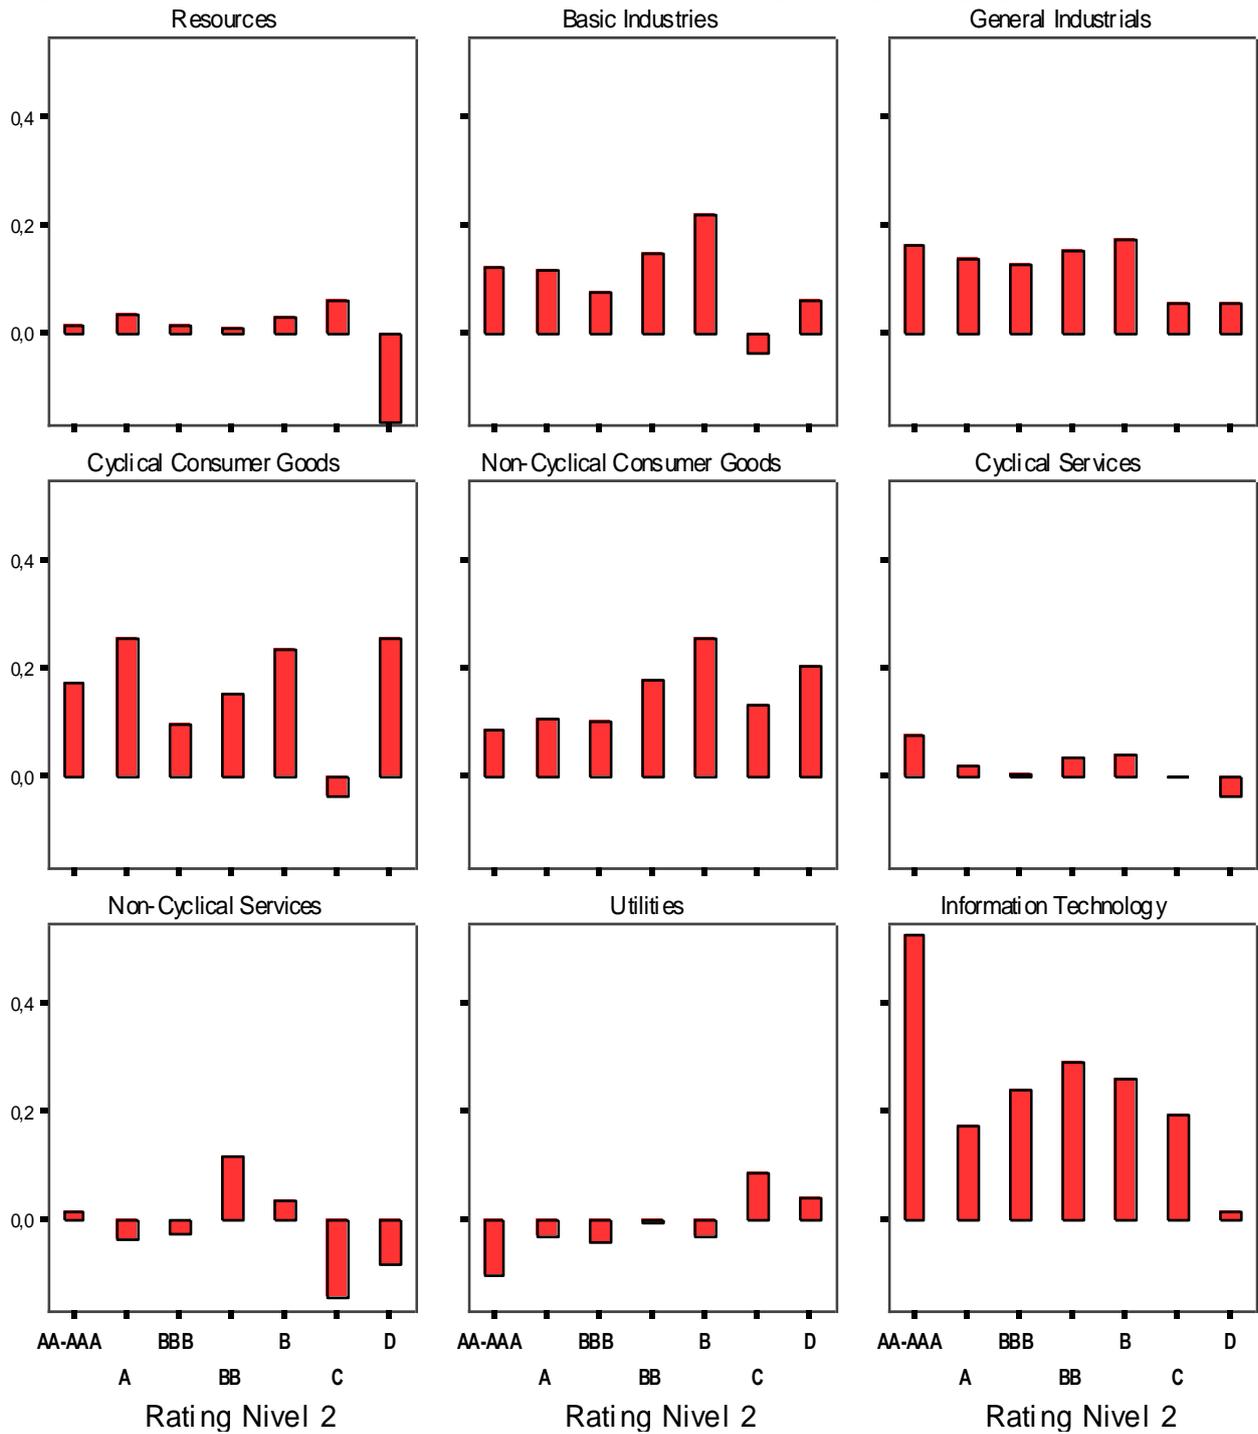


Figura A 20. Gráficos de barra de medianas de las variables l_wc_ltd agrupada por rating y por sector industrial



C.7. Acerca del análisis de las variables agrupadas

Tabla A 18. Estadísticos de las variables agrupadas por rating

		Rating Nivel 2						
		AA-AAA	A	BBB	BB	B	C	D
Rango	t_vtas	244496510	81185984	186156775	23270992	15381429	3286026	32201984
	t_vm	277028955	142487394	58637080	19182507	11594269	2171389	528307
	a_s_ta	3,8884	3,3357	4,7932	5,0307	3,7923	3,4832	2,9321
	a_cf_s	13,6179	0,8644	0,8461	14,3086	40,3747	1,4135	337,0307
	a_vvtas	1,1892	1,3652	3,3113	2,2549	2,3152	2,3643	1,5084
	a_cf_td	0,9029	1,0672	1,1002	6,9818	1,8517	0,8114	0,8007
	f_ltd_ce	9,1659	29,0274	41,8076	216,6149	510,1787	110,1080	651,9387
	f_fa_ce	7,1092	38,3466	33,2625	58,1592	381,3647	70,7365	924,6718
	f_td_ta	0,7484	0,9327	1,3240	1,9717	3,0917	1,5455	2,8050
	f_dp_e	11,9404	25,4901	126,1667	50,6211	5,2260	0,1182	1,2657
	f_mve_tl	0,0176	0,0452	0,0087	0,0120	0,0133	0,0049	0,0009
	f_td_ce	18,4261	95,2409	150,4013	265,4501	610,6514	153,7975	1126,8405
	l_s_wc	308,1954	5711,3326	2076,7085	3967,5857	1249,0883	509,4701	96,5965
	l_wc_ltd	221,0194	24,5818	180,8588	79,1702	2491,8504	37,7020	2425,3273
	l_wc_ta	0,6983	0,9980	1,3397	1,3083	1,8856	1,2998	3,1041
	l_cl_ta	0,4227	0,6735	1,0619	0,6842	1,3726	1,0316	2,9372
	l_quick	7,8395	7,9400	6,4446	57,6637	41,4002	3,6345	3,5514
	l_cas_ta	0,6745	0,7846	0,7347	0,8802	0,9178	0,5895	0,5863
	l_cas_cl	7,8163	8,1379	6,8116	58,4205	41,8898	3,6955	4,0168
	l_ca_cl	7,7629	8,3283	7,4023	58,2579	41,8161	3,6918	4,0093
	l_c_cl	3,0330	6,8624	5,9922	56,8869	41,4611	2,6749	3,5945
	l_i_tca	0,8166	0,9142	0,9486	0,9765	0,9155	0,6194	0,8028
	l_ca_ta	0,6760	0,7881	0,9528	0,9148	0,9178	0,6836	0,6920
	l_cl_tl	0,7836	0,8278	1,1220	1,0887	1,2697	0,8940	0,9690
	g_ebit_i	58,6415	155,1388	75,3890	262,4918	906,8684	54,1210	39,2962
	g_nia_ta	0,3770	0,7389	0,7984	1,9279	2,6023	2,2481	8,3827
	g_ebit_s	13,6128	1,1906	2,0655	4,1682	64,1153	6,1036	585,0812
g_ronfa	61,3098	4,5670	9,4945	53,8893	38,2159	11,3934	20,3420	
g_ebit_a	0,2593	0,5077	0,6371	1,6223	2,8021	2,0385	8,2950	
g_roe	3,8152	11,1967	12,1079	16,4102	64,1781	25,2127	1926,3964	
g_re_ta	0,8487	1,2883	2,2232	5,2392	19,4067	21,1838	4,1394	
v_vol250	45,4400	89,1400	138,3700	117,9900	202,3700	163,5200	551,1800	
Media	t_vtas	30766191	10380200	7613764	2518966	1369791	544830	2082307
	t_vm	55265474	13170793	4723713	1258039	750846	166222	68755
	a_s_ta	0,9173	0,8657	0,9646	1,0621	0,9096	0,7861	1,0219
	a_cf_s	0,4599	0,1542	0,1322	0,1737	-0,1990	-0,0334	-9,3619
	a_vvtas	-0,0025	0,0060	0,0143	0,0204	-0,0224	0,1170	-0,1114
	a_cf_td	0,2803	0,1947	0,1551	0,1626	0,0476	0,0248	0,0015
	f_ltd_ce	0,8581	0,5581	1,2006	1,8581	5,0998	-0,3932	17,2899
	f_fa_ce	1,5211	1,0780	1,5098	1,6534	4,0951	1,7287	26,9852
	f_td_ta	0,5748	0,6056	0,6442	0,6714	0,7565	1,0402	1,2935
	f_dp_e	0,6739	0,3824	0,2097	-0,0152	0,0353	-0,0031	-0,0362
	f_mve_tl	0,0035	0,0022	0,0012	0,0011	0,0008	0,0003	0,0001
	f_td_ce	2,1758	1,5925	2,7281	3,2926	6,2968	-0,7653	32,2464
	l_s_wc	9,2322	-22,1473	-2,6675	-10,8072	6,7937	-6,6594	0,2748
	l_wc_ltd	3,5573	0,8253	1,4526	0,3571	22,0158	-1,1036	-65,5945
	l_wc_ta	0,0624	0,0797	0,0804	0,1527	0,1782	-0,0376	-0,2084
	l_cl_ta	0,2565	0,2521	0,2440	0,2180	0,2244	0,3540	0,5808
	l_quick	1,0017	0,9583	0,9038	1,2522	2,0830	0,8719	0,8058
	l_cas_ta	0,2544	0,2426	0,2307	0,2334	0,3092	0,2605	0,2686
	l_cas_cl	1,1354	1,1068	1,0307	1,4149	2,2589	1,0008	0,9178
	l_ca_cl	1,3649	1,4839	1,4315	2,0691	2,7022	1,1786	1,2524
	l_c_cl	0,3927	0,3738	0,3220	0,6532	1,5028	0,4855	0,4045
	l_i_tca	0,2089	0,2441	0,2621	0,3118	0,2122	0,1635	0,2267
	l_ca_ta	0,3189	0,3318	0,3244	0,3707	0,4026	0,3163	0,3724
	l_cl_tl	0,4768	0,4191	0,3844	0,3380	0,3104	0,3429	0,4488
	g_ebit_i	11,9105	5,6377	1,9363	-0,4722	-8,3122	-4,5452	-0,6641
	g_nia_ta	0,1216	0,0843	0,0651	0,0460	-0,0281	-0,1882	0,1860
	g_ebit_s	0,3606	0,0477	0,0219	0,0018	-0,6126	-0,6861	-16,2864
g_ronfa	1,5501	0,1984	0,1071	0,2467	-0,6581	-1,3632	0,4562	
g_ebit_a	0,0761	0,0435	0,0255	0,0036	-0,0963	-0,3009	0,0963	
g_roe	0,2602	0,1488	0,0400	0,0293	-0,5283	0,3246	45,2100	
g_re_ta	0,3850	0,2913	0,1785	0,0615	-0,4568	-2,0478	-0,9281	
v_vol250	31,1089	36,4681	41,8281	55,5740	86,9996	126,2254	198,2052	

... continúa

continuación...

		AA-AAA	A	BBB	BB	B	C	D	
Desv. típ.	t_vtas	42679766	13826069	16856350	3414003	2488305	702518	5607636	
	t_vm	67002137	20375151	6243881	1758314	1572308	422448	118577	
	a_s_ta	0,6264	0,5518	0,6690	0,8192	0,6695	0,6535	0,6949	
	a_cf_s	1,9084	0,0976	0,1051	0,8229	2,8688	0,2658	56,1332	
	a_vvtas	0,1682	0,1579	0,2567	0,2483	0,2969	0,5069	0,2645	
	a_cf_td	0,1691	0,1277	0,1107	0,4039	0,1980	0,1545	0,1275	
	f_ltd_ce	1,4988	2,4543	2,8626	10,7872	40,5981	15,3637	102,0216	
	f_fa_ce	1,5867	2,2051	2,2754	4,1892	30,2516	9,8506	149,8592	
	f_td_ta	0,1659	0,1593	0,1670	0,1880	0,3425	0,3360	0,7456	
	f_dp_e	1,6557	1,6095	4,9665	2,2777	0,3739	0,0179	0,2079	
	f_mv_e_tl	0,0036	0,0036	0,0012	0,0015	0,0012	0,0008	0,0002	
	f_td_ce	2,8245	6,5599	7,9293	15,6492	49,4115	21,8354	180,4335	
	l_s_wc	44,3824	324,6124	105,5283	217,8157	84,1144	65,7785	17,0695	
	l_wc_ltd	25,4402	2,5621	12,4266	4,4280	198,0676	5,9538	384,3282	
	l_wc_ta	0,1432	0,1524	0,1588	0,1904	0,2465	0,2997	0,6377	
	l_cl_ta	0,0867	0,1298	0,1295	0,1240	0,1778	0,2552	0,6303	
	l_quick	1,1430	0,8096	0,7068	3,4640	4,1777	0,6859	0,7012	
	l_cas_ta	0,1399	0,1388	0,1437	0,1596	0,2120	0,1636	0,1468	
	l_cas_cl	1,1559	0,8442	0,7373	3,5017	4,2483	0,7312	0,7950	
	l_ca_cl	1,1391	0,9681	0,8652	3,5930	4,2034	0,7083	0,9496	
	l_c_cl	0,4934	0,6661	0,5785	3,4099	4,2115	0,5556	0,6801	
	l_i_tca	0,1616	0,1744	0,1907	0,2400	0,2250	0,2059	0,2658	
	l_ca_ta	0,1613	0,1785	0,1941	0,2225	0,2319	0,1841	0,1803	
	l_cl_tl	0,1853	0,1775	0,1816	0,1896	0,2184	0,2260	0,3126	
	g_ebit_i	12,4356	16,2848	5,5793	13,9543	62,3919	7,8367	7,3913	
	g_nia_ta	0,0752	0,0830	0,0755	0,1316	0,2431	0,3818	1,2933	
	g_ebit_s	1,9037	0,1157	0,1530	0,2140	4,5050	1,0549	96,9752	
	g_ronfa	8,6312	0,4285	0,5761	3,0602	2,8138	2,4373	3,3945	
	g_ebit_a	0,0572	0,0584	0,0622	0,1149	0,2583	0,3731	1,2654	
	g_roe	0,5233	0,7925	0,6549	0,9946	4,5316	4,0853	294,4449	
	g_re_ta	0,2173	0,2274	0,2165	0,3745	1,4543	4,0973	1,1387	
	v_vol250	9,5439	10,8703	15,4843	21,9463	36,8834	41,5526	134,7949	
	Asimetría	t_vtas	3,2378	2,5284	7,0568	2,9916	3,6562	2,8004	4,8318
		t_vm	1,7653	3,5905	3,6894	5,4545	4,5776	4,1729	2,7568
		a_s_ta	2,5873	1,8024	2,0117	1,8660	1,2050	2,3444	0,8423
		a_cf_s	7,0438	0,8070	1,9793	16,4171	-13,5620	-1,3531	-6,0000
		a_vvtas	-4,4380	-0,3892	3,2926	0,3249	0,8735	1,6154	-1,6678
		a_cf_td	2,0573	2,0088	1,8157	14,6790	-2,0228	1,0898	0,1901
		f_ltd_ce	4,0101	-8,4164	4,2774	7,8417	8,8745	-1,4521	6,0155
		f_fa_ce	2,2013	2,8493	5,1862	3,6018	8,1973	2,2109	5,8568
		f_td_ta	-0,0995	-0,2361	0,7923	1,3142	0,7465	0,8629	1,3675
		f_dp_e	6,5458	9,3076	-3,3738	-3,1666	12,3986	-4,0604	-6,0686
		f_mv_e_tl	2,1027	8,7852	2,5435	4,0059	-0,0592	5,0559	2,6630
		f_td_ce	4,4497	-5,8643	-0,0615	6,7677	8,0770	-1,4138	5,7631
		l_s_wc	1,2350	-8,1866	-4,2135	-10,4472	9,1933	-5,3546	-2,0590
		l_wc_ltd	5,7134	4,7878	12,7505	-11,7062	11,1214	-5,1621	-5,0258
		l_wc_ta	0,9470	0,5380	0,5448	0,8270	-0,2114	-1,9383	-2,1109
l_cl_ta		0,0059	0,9718	1,3722	1,0707	2,7996	1,4474	2,2482	
l_quick		5,0014	4,5800	4,4327	15,1692	6,6728	1,7737	1,9372	
l_cas_ta		0,7752	1,2281	0,8690	1,5613	0,8537	0,6594	0,4512	
l_cas_cl		4,7137	4,3124	4,2592	15,1075	6,5747	1,5593	2,0254	
l_ca_cl		4,2943	3,1173	2,7536	13,5534	6,4054	1,1004	1,0834	
l_c_cl		3,4511	5,7785	5,7616	15,5200	6,7991	1,8268	3,4676	
l_i_tca		1,6168	0,3962	0,6438	0,4265	1,2165	1,0730	0,8128	
l_ca_ta		0,1344	0,5753	0,6667	0,5382	0,2342	0,5564	0,0482	
l_cl_tl		0,1676	0,4113	0,7125	0,9975	1,1767	1,3749	0,4139	
g_ebit_i		1,2823	5,5894	0,5165	-14,5483	-13,3564	-4,3367	2,7434	
g_nia_ta		0,3210	0,2834	-0,9432	-4,5354	-1,2280	-1,7400	4,3955	
g_ebit_s		7,0554	-4,0853	-6,5911	-1,6375	-12,8684	-2,5937	-5,9990	
g_ronfa		7,0272	3,9289	0,1258	-4,1873	1,3707	-2,4611	4,2938	
g_ebit_a		0,4337	-0,0882	-2,5517	-3,8992	-2,1160	-1,8808	4,2745	
g_roe		5,9660	2,7331	-6,5073	1,9405	-9,3997	-1,2439	6,0132	
g_re_ta	0,7194	0,6493	-0,8607	-4,1815	-8,0601	-3,5327	-1,1677		
v_vol250	0,5410	1,5225	1,7467	1,0599	0,9533	0,2788	0,9508		

... continúa

continuación...

		AA-AAA	A	BBB	BB	B	C	D
Curtosis	t_vtas	12,8877	6,9470	62,1713	10,9805	14,3611	8,8149	24,7927
	t_vm	2,6506	15,7418	20,8790	44,9610	23,9971	17,2964	8,0818
	a_s_ta	10,2858	4,8606	6,6059	4,4850	1,5632	7,5619	0,9916
	a_cf_s	49,7369	3,3124	6,4386	277,9567	187,7144	2,9932	35,9997
	a_vvtas	25,4392	5,1470	28,4624	6,1959	5,2955	2,8260	5,6721
	a_cf_td	5,6153	7,4757	7,6337	238,5623	11,4814	2,5796	5,5605
	f_ltd_ce	19,5140	80,0095	38,2994	123,4003	88,3412	10,9801	36,4432
	f_fa_ce	4,6665	65,3344	44,9520	33,7189	76,5943	10,6346	34,7582
	f_td_ta	-0,1285	0,5714	3,3401	8,7903	3,7187	0,7869	1,2117
	f_dp_e	44,5895	122,1212	162,2327	110,9538	163,6946	17,9120	36,8791
	f_mve_tl	5,3818	100,5528	8,9361	21,2259	14,6242	28,0366	7,5212
	f_td_ce	24,0141	58,4050	61,2169	84,2650	75,3740	9,8915	34,0917
	l_s_wc	6,8064	107,5352	73,0922	145,2587	106,2479	33,2742	7,0260
	l_wc_ltd	39,2883	27,6604	164,5380	166,7783	131,9422	28,0491	26,8562
	l_wc_ta	1,7007	0,7492	2,2793	1,0895	3,2512	3,6409	5,1130
	l_cl_ta	0,2063	1,1274	4,8819	1,2298	12,3327	1,6306	5,5588
	l_quick	29,5341	31,7697	29,2407	246,1379	52,2465	5,7514	6,1724
	l_cas_ta	1,1206	2,0422	0,2645	3,2870	-0,0477	-0,5240	-0,6142
	l_cas_cl	26,6577	28,5417	27,4476	245,0693	50,9866	4,0473	6,6688
	l_ca_cl	23,8141	16,5257	13,1211	209,1808	49,4677	3,3339	1,2451
	l_c_cl	16,3203	46,1209	43,7004	254,9182	53,6910	4,6531	14,1976
	l_i_tca	4,2459	-0,4255	0,1048	-0,7555	0,8679	-0,3333	-0,8343
	l_ca_ta	-0,4363	-0,1300	-0,1077	-0,4103	-0,9074	-0,5479	-0,5985
	l_cl_tl	-0,5101	-0,4229	0,6365	1,1261	1,3630	1,4355	-1,1150
	g_ebit_i	1,3267	37,2080	17,4595	237,3809	183,5292	23,6506	8,9799
	g_nia_ta	0,2081	4,5356	7,3787	45,4575	10,5628	5,3073	22,3724
	g_ebit_s	49,8494	28,3921	58,6081	63,9473	173,6307	8,9719	35,9918
	g_ronfa	49,5677	26,2956	41,7855	83,0829	32,0751	5,8160	20,1636
	g_ebit_a	-0,2785	3,8567	14,1408	33,4939	13,6876	4,8967	21,7703
	g_roe	38,9070	43,2059	83,8680	38,8649	108,1872	6,1990	36,4523
	g_re_ta	-0,2521	0,5771	7,7089	36,4151	84,7678	13,0480	0,3526
	v_vol250	0,1458	5,7865	6,1936	0,9876	0,9045	-0,7150	0,6793

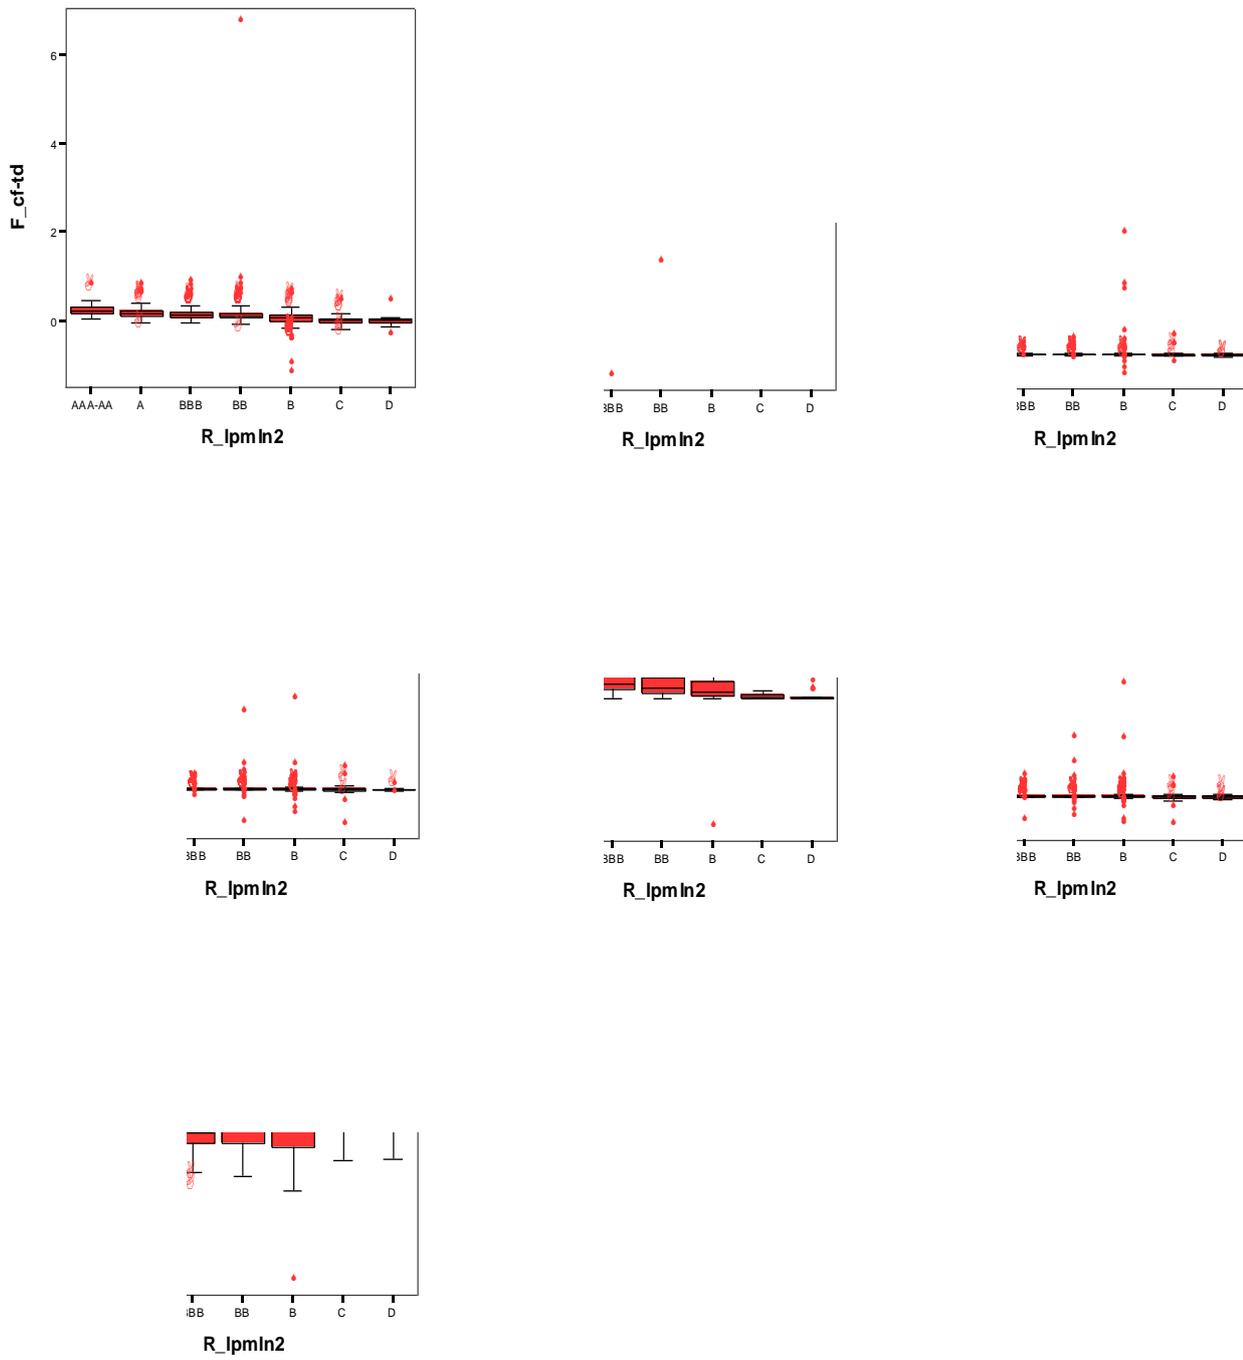
Tabla A 19. Comparación entre media y mediana de las variables de la muestra agrupadas por rating

	AA-AAA		A		BBB		BB		B		C		D	
	Mean	Median	Mean	Median	Mean	Median	Mean	Median	Mean	Median	Mean	Median	Mean	Median
t_vtas	30.550.072	16.833.534	10.550.741	5.384.425	7.905.068	3.108.686	2.551.533	1.229.825	1.416.236	546.547	551.598	272.116	3.250.874	666.911
t_vm	51.213.186	24.219.048	13.381.917	6.747.340	4.715.959	2.401.603	1.267.470	681.470	778.739	276.058	172.558	40.866	88.449	32.920
a_cf-s	0,462	0,175	0,154	0,129	0,129	0,101	0,177	0,087	-0,218	0,061	-0,011	0,019	-0,017	0,013
a_s-ta	0,939	0,844	0,881	0,794	0,983	0,853	1,055	0,860	0,908	0,725	0,803	0,621	1,051	1,088
a_vvtas	-0,005	0,017	0,004	0,001	0,019	0,005	0,014	0,013	-0,022	0,002	0,102	0,021	-0,067	-0,096
f_cf-td	0,269	0,242	0,193	0,167	0,158	0,131	0,164	0,111	0,046	0,071	0,020	0,018	0,007	0,015
f_ltd-ce	0,824	0,379	0,546	0,580	1,210	0,809	2,036	0,979	5,693	0,828	-1,398	-0,963	32,819	0,000
f_fa-ce	1,464	1,008	1,090	0,986	1,498	1,191	1,754	0,954	4,463	0,495	1,830	-0,384	46,422	-0,521
f_td-ta	0,576	0,585	0,608	0,615	0,646	0,646	0,665	0,661	0,756	0,732	1,047	1,012	1,102	1,048
f_mv-e-tl	0,003	0,002	0,002	0,001	0,001	0,001	0,001	0,001	0,001	0,000	0,000	0,000	0,000	0,000
f_dp-e	0,694	0,397	0,377	0,333	0,196	0,161	-0,065	0,000	0,038	0,000	-0,003	0,000	-0,001	0,000
f_td-ce	2,145	1,447	1,559	1,670	2,752	1,864	3,613	1,932	7,076	1,434	-1,910	-2,277	55,386	-1,731
l_s-wc	9,646	5,090	-19,934	4,006	-0,613	4,233	-11,859	4,771	7,915	3,474	-7,076	2,393	5,067	4,259
l_wc-ltd	3,638	0,166	0,797	0,260	1,493	0,177	0,339	0,297	20,802	0,305	-1,134	0,086	-108,667	0,098
l_wc-ta	0,057	0,041	0,080	0,053	0,080	0,052	0,150	0,117	0,191	0,162	-0,016	0,047	-0,130	0,061
l_cas-ta	0,245	0,239	0,241	0,216	0,231	0,203	0,236	0,204	0,314	0,265	0,266	0,226	0,245	0,224
l_ca-ta	0,316	0,326	0,333	0,323	0,327	0,300	0,368	0,341	0,409	0,421	0,324	0,306	0,352	0,367
l_cl-tl	0,474	0,486	0,416	0,400	0,385	0,367	0,337	0,301	0,303	0,258	0,331	0,258	0,415	0,397
l_cl-ta	0,259	0,260	0,253	0,237	0,246	0,225	0,218	0,193	0,218	0,188	0,340	0,276	0,482	0,283
l_quick	0,969	0,832	0,937	0,759	0,895	0,774	1,273	0,849	2,120	1,118	0,883	0,823	0,756	0,714
l_cas-cl	1,081	0,928	1,087	0,888	1,029	0,892	1,446	1,008	2,308	1,302	1,017	0,966	0,852	0,769
l_ca-cl	1,338	1,190	1,475	1,256	1,430	1,221	2,097	1,618	2,756	1,782	1,201	1,267	1,185	1,249
l_c-cl	0,345	0,246	0,377	0,189	0,314	0,143	0,677	0,217	1,540	0,472	0,479	0,264	0,332	0,143
l_i-tca	0,213	0,189	0,250	0,235	0,264	0,259	0,309	0,292	0,207	0,125	0,167	0,047	0,247	0,220
g_ebit-i	12,145	7,670	5,654	2,530	1,973	1,507	-0,620	0,490	-9,046	-0,808	-4,561	-3,670	-2,253	-1,725
g_nia-ta	0,122	0,122	0,086	0,083	0,067	0,067	0,043	0,053	-0,039	0,022	-0,193	-0,084	-0,124	-0,051
g_ebit-a	0,077	0,071	0,044	0,043	0,027	0,032	0,002	0,015	-0,108	-0,038	-0,307	-0,176	-0,191	-0,132
g_ebit-s	0,369	0,079	0,048	0,059	0,028	0,038	-0,001	0,015	-0,673	-0,056	-0,672	-0,269	-0,281	-0,125
g_ronfa	1,542	0,154	0,203	0,113	0,126	0,082	0,169	0,038	-0,716	-0,111	-1,360	-0,409	-0,362	-0,197
g_roe	0,266	0,175	0,151	0,122	0,046	0,098	0,033	0,045	-0,588	-0,021	0,653	0,586	-7,327	0,352
g_re-ta	0,393	0,350	0,298	0,266	0,181	0,169	0,065	0,107	-0,468	-0,134	-1,973	-0,738	-0,722	-0,216
v_vol250	31,136	30,395	36,407	34,860	41,944	39,020	56,141	50,450	86,857	77,830	125,634	121,860	220,981	179,430

Tabla A 20. Valores extremos para cada variable de las compañías de la muestra agrupadas por rating

Variable	AAA; AA		A		BBB		BB		B		C		D		Total	V.E. sin agrupa	Cambio %
	Bajos	Altos	Bajos	Altos	Bajos	Altos	Bajos	Altos	Bajos	Altos	Bajos	Altos	Bajos	Altos			
t_vtas	0	8	0	21	0	39	0	35	0	22	0	2	0	3	130	144	90%
t_vm	0	8	0	25	0	25	0	26	0	20	0	3	0	3	110	149	74%
a_s_ta	0	2	0	8	0	12	0	17	0	4	0	3	0	2	48	52	92%
a_cf_s	0	2	1	9	1	12	1	26	20	9	5	2	2	1	91	98	93%
a_vvtas	3	0	7	5	22	17	14	13	10	7	1	5	2	1	107	116	92%
f_cf_td	0	3	1	10	1	16	1	21	20	11	1	3	2	3	93	91	102%
f_ltd_ce	0	6	3	19	6	26	13	42	21	20	3	4	3	6	172	191	90%
f_fa_ce	0	6	3	2	3	11	8	20	15	15	1	4	3	3	94	110	85%
f_td_ta	0	0	2	3	2	5	1	5	1	6	0	4	0	4	33	64	52%
f_dp_e	1	4	9	8	14	20	40	70	0	0	0	0	0	0	166	123	135%
f_mve_tl	0	3	0	14	0	23	0	23	1	13	0	3	0	5	85	97	88%
f_td_ce	0	6	3	21	7	29	13	30	25	23	3	5	4	4	173	208	83%
l_s_wc	4	6	20	13	29	27	34	34	28	12	4	1	4	3	219	199	110%
l_wc_ltd	2	7	2	16	6	34	3	19	1	14	3	2	6	4	119	122	98%
l_wc_ta	0	2	2	2	4	9	2	4	3	3	4	0	3	0	38	61	62%
l_cl_ta	0	1	0	7	0	5	0	8	0	8	0	3	0	3	35	43	81%
l_quick	0	2	0	15	0	14	0	18	0	14	0	1	0	1	65	79	82%
l_cas_ta	0	1	0	8	0	3	0	10	0	1	0	0	0	0	23	30	77%
l_cas_cl	0	2	0	14	0	11	0	19	0	14	0	1	0	1	62	77	81%
l_ca_cl	0	2	0	9	0	12	0	13	0	15	0	1	0	1	53	61	87%
l_c_cl	0	2	0	19	0	27	0	31	0	20	0	1	0	2	102	116	88%
l_i_tca	0	2	0	0	0	3	0	0	0	6	0	0	0	0	11	6	183%
l_ca_ta	0	0	0	0	0	2	0	0	0	0	0	0	0	0	2	1	200%
l_cl_tl	0	0	0	0	0	4	0	5	1	10	0	3	0	0	23	20	115%
g_ebit_i	0	1	11	20	22	28	23	14	30	3	2	0	0	4	158	180	88%
g_nia_ta	0	0	8	8	18	5	12	4	12	4	2	1	3	4	81	123	66%
g_ebit_s	0	2	17	11	23	8	25	8	19	2	2	0	8	4	129	171	75%
g_ronfa	0	3	7	10	21	32	22	33	33	6	7	0	2	4	180	220	82%
g_ebit_a	0	0	15	6	23	6	18	6	14	3	3	0	3	5	102	151	68%
g_roe	0	3	12	13	31	18	28	15	20	15	3	3	4	4	169	220	77%
g_re_ta	0	1	0	4	8	6	13	5	14	1	4	0	0	0	56	125	45%
v_vol250	0	1	0	5	2	20	0	13	0	4	0	0	0	1	46	100	46%
Suma	10	86	123	325	243	509	271	587	288	305	48	55	49	76	2975	3548	84%
Total V.E.	96		448		752		858		593		103		125				
% del total	3%		15%		25%		29%		20%		3%		4%		100%		
Distrib.todos datos	4%		18%		29%		25%		17%		4%		3%		100%		

Figura A 21. Diagramas de caja de las variables de financiación agrupadas por rating



C.8. Acerca de las variables agrupadas por país y sector industrial

Tabla A 21. Estadísticos de las variables agrupadas por país

		Bloque de países						
		EUROPE	JAPAN	U.S.	CANADA	Sin agrupar		
Rango	t_vtas	80205118	125770465	244523984	14612550	244523984		
	t_vm	142502553	146671903	277060035	17309840	277060035		
	a_s_ta	3,4791	1,4013	5,0307	2,4172	5,0307		
	a_cf_s	14,0755	0,4743	350,8820	0,9692	350,8820		
	a_vvtas	1,7156	0,6643	3,4827	2,0968	3,4827		
	f_cf_td	1,2470	0,7180	7,9413	0,7204	7,9413		
	f_ltd_ce	31,8969	4,1578	688,2550	31,1391	688,2550		
	f_fa_ce	23,7583	6,1980	949,4178	62,0802	949,4178		
	f_td_ta	1,3783	0,5417	3,8758	2,8009	3,8758		
	f_dp_e	8,9300	21,7141	126,1667	7,1453	126,1667		
	f_mv_e_tl	0,0452	0,0052	0,0256	0,0041	0,0529		
	f_td_ce	73,4155	5,9467	1176,8737	75,4470	1176,8737		
	l_s_wc	1141,9996	88,5313	5711,3326	3338,0567	5711,3326		
	l_wc_ltd	76,3599	11,4432	4539,3490	267,6881	4539,3490		
	l_wc_ta	1,3627	0,6856	2,4798	3,1206	3,5088		
	l_cl_ta	1,0236	0,4537	2,0735	2,9355	2,9637		
	l_quick	7,8612	2,5926	57,7128	5,7145	57,7128		
	l_cas_ta	0,5460	0,4497	0,9209	0,6028	0,9228		
	l_cas_cl	7,8489	2,8783	58,4521	5,8226	58,4521		
	l_ca_cl	7,8434	4,7464	58,4234	5,8731	58,4234		
	l_c_cl	2,6510	1,7060	56,8869	3,8354	56,8869		
	l_i_tca	0,8719	0,3502	0,9765	0,6682	1,1781		
	l_ca_ta	0,8629	0,6050	0,9610	0,8043	0,9610		
	l_cl_tl	1,0512	0,5892	1,3751	0,9192	1,4415		
	g_ebit_i	67,0324	38,9200	990,7802	42,5805	990,7802		
	g_nia_ta	0,9436	0,1924	8,6763	1,2716	8,6763		
	g_ebit_s	15,9059	0,1344	585,0812	1,4325	595,4886		
g_ronfa	65,2700	0,5368	60,2798	2,8201	98,2852			
g_ebit_a	1,0172	0,1291	8,4496	1,3265	8,4496			
g_roe	10,0668	0,5898	1926,3964	17,5754	1926,3964			
g_re_ta	2,8629	0,4153	23,4963	3,3891	23,4963			
v_vol250	205,2000	60,2200	551,1800	207,2100	551,1800			
Media	t_vtas	7434794,3	35550282	5680866,1	2505101,4	6330110		
	t_vm	7004060,1	26460868	6314663,6	2693485,2	6592571		
	a_s_ta	0,8614	0,8346	0,9950	0,7263	0,9558		
	a_cf_s	0,2075	0,1355	-0,2953	0,1530	-0,1923		
	a_vvtas	-0,0042	0,0376	0,0025	0,0703	0,0073		
	f_cf_td	0,1350	0,1604	0,1424	0,1436	0,1420		
	f_ltd_ce	0,7530	1,0720	2,6618	1,9444	2,3397		
	f_fa_ce	1,1996	1,7650	2,9144	3,1307	2,6937		
	f_td_ta	0,6796	0,6010	0,7013	0,6755	0,6945		
	f_dp_e	0,2474	1,4742	0,1105	0,1300	0,1591		
	f_mv_e_tl	0,0013	0,0012	0,0013	0,0011	0,0013		
	f_td_ce	2,3642	2,3659	4,4105	3,4683	4,0454		
	l_s_wc	-9,7130	3,1686	-3,1985	-35,9829	-6,1978		
	l_wc_ltd	0,0186	1,2554	3,7482	-2,9680	2,7395		
	l_wc_ta	0,0345	0,0757	0,1194	0,0248	0,1012		
	l_cl_ta	0,3178	0,2791	0,2411	0,2259	0,2504		
	l_quick	0,8734	0,8780	1,2878	0,9003	1,1992		
	l_cas_ta	0,2656	0,2875	0,2536	0,1691	0,2498		
	l_cas_cl	0,9636	1,0472	1,4493	0,9771	1,3460		
	l_ca_cl	1,2551	1,3088	1,9335	1,4135	1,7983		
	l_c_cl	0,2836	0,4028	0,7094	0,3590	0,6247		
	l_i_tca	0,2264	0,2032	0,2595	0,2887	0,2562		
	l_ca_ta	0,3522	0,3548	0,3605	0,2508	0,3515		
	l_cl_tl	0,4704	0,4895	0,3570	0,3141	0,3710		
	g_ebit_i	0,0910	2,1285	0,3138	1,0265	0,3782		
	g_nia_ta	0,0282	0,0257	0,0489	0,0411	0,0453		
	g_ebit_s	0,0407	0,0105	-0,7675	-0,0061	-0,5976		
g_ronfa	0,3397	0,0134	0,0138	-0,0341	0,0502			
g_ebit_a	-0,0146	0,0070	-0,0032	-0,0052	-0,0046			
g_roe	0,0504	0,0160	1,7953	-0,1227	1,4046			
g_re_ta	0,0586	0,2211	-0,0713	-0,0203	-0,0458			
v_vol250	47,5187	31,9073	61,7155	46,0139	58,1245			
Desv. tip.	t_vtas	10767460	34374226	14952669	3030138	15344957		
	t_vm	16621391	34284512	20647597	3668952	20090031		
	a_s_ta	0,4969	0,3669	0,7360	0,4866	0,6931		
	a_cf_s	1,1333	0,1137	11,1962	0,1618	9,9244		
	a_vvtas	0,1660	0,1247	0,2743	0,2435	0,2592		
	f_cf_td	0,1221	0,1388	0,2709	0,1312	0,2469		
	f_ltd_ce	2,3653	1,1534	28,6449	4,8905	25,3998		
	f_fa_ce	1,9749	1,7396	32,9274	7,9685	29,2306		
	f_td_ta	0,2017	0,1768	0,2956	0,3351	0,2869		
	f_dp_e	0,8150	4,5674	3,2801	0,8891	3,0070		
	f_mv_e_tl	0,0039	0,0012	0,0018	0,0009	0,0021		
	f_td_ce	5,9487	1,8801	44,1811	9,3846	39,2323		
	l_s_wc	109,3158	17,9357	181,2619	346,0672	188,8846		
	l_wc_ltd	5,6602	2,5745	115,6186	29,1312	102,4156		
	l_wc_ta	0,1733	0,1592	0,2247	0,3265	0,2291		
	l_cl_ta	0,1528	0,1103	0,1769	0,3236	0,1889		
	l_quick	0,7921	0,5693	2,8367	0,8285	2,5390		
	l_cas_ta	0,1289	0,1449	0,1696	0,1173	0,1628		
	l_cas_cl	0,7890	0,6084	2,8798	0,8504	2,5797		
	l_ca_cl	0,8443	0,9365	2,9248	1,0194	2,6339		
	l_c_cl	0,3194	0,4460	2,8164	0,6654	2,5054		
	l_i_tca	0,1699	0,0959	0,2213	0,2031	0,2126		
	l_ca_ta	0,1632	0,1967	0,2121	0,1757	0,2055		
	l_cl_tl	0,1665	0,1771	0,2030	0,1756	0,2011		
	g_ebit_i	6,9137	8,8094	31,5370	4,4351	28,0705		
	g_nia_ta	0,1236	0,0508	0,3090	0,1274	0,2791		
	g_ebit_s	1,1768	0,0393	19,3094	0,2104	17,1121		
g_ronfa	5,1821	0,1187	2,3910	0,4048	2,7870			
g_ebit_a	0,1321	0,0329	0,3044	0,1394	0,2760			
g_roe	0,8638	0,1188	58,9976	1,7413	52,2290			
g_re_ta	0,3459	0,1180	1,2651	0,5106	1,1391			
v_vol250	27,8675	12,3266	45,8163	35,9869	43,3470			

... continúa

continuación...

		EUROPE	JAPAN	U.S.	CANADA	Sin agrupar
Asimetr	t_vtas	3,4142	1,2855	9,1244	2,2326	7,7152
	t_vm	6,1538	2,4968	7,9122	2,2936	7,5600
	a_s_ta	1,5795	0,3512	1,8050	1,4930	1,8823
	a_cf_s	11,8793	0,9175	-29,6533	0,5300	-33,3996
	a_vvtas	-0,9620	3,1121	1,6192	2,3432	1,6064
	f_cf_td	2,6025	1,9573	15,6570	0,7508	16,2549
	f_ltd_ce	-0,1133	1,4321	16,4307	3,8717	18,4789
	f_fa_ce	0,0595	1,6360	23,0638	5,5462	25,8352
	f_td_ta	0,8698	-0,0655	2,6939	4,8725	2,9009
	f_dp_e	-2,0912	3,7126	-4,5621	-3,2342	-4,3631
	f_mve_tl	10,2895	2,1264	3,1607	1,5747	9,1891
	f_td_ce	1,0694	1,0702	18,3215	5,1529	20,5055
	l_s_wc	-4,1132	0,1850	-11,2550	-8,8026	-11,6755
	l_wc_ltd	-10,4092	2,9206	5,8878	-9,1031	6,6137
	l_wc_ta	-0,7225	0,6541	-1,0749	-6,4853	-2,1497
	l_cl_ta	1,6416	1,0290	3,7043	7,6298	5,0409
	l_quick	6,1130	1,4099	13,7318	3,7511	15,0767
	l_cas_ta	0,6468	-0,5550	1,2454	1,4535	1,2005
	l_cas_cl	5,9343	1,4113	13,5757	3,5591	14,8875
	l_ca_cl	4,3221	2,3806	12,5354	2,1118	13,5793
l_c_cl	4,0133	1,8028	14,0505	3,4393	15,7035	
l_i_tca	0,2813	0,4450	0,7522	0,2299	0,7262	
l_ca_ta	0,4755	-0,4087	0,5317	1,1579	0,5549	
l_cl_tl	0,6434	-0,2466	0,8733	1,2274	0,7609	
g_ebit_i	-0,8298	1,0369	-22,6516	2,4391	-25,1534	
g_nia_ta	-2,1072	-0,6735	12,2967	-3,7233	13,0469	
g_ebit_s	10,6884	-0,7315	-29,8005	-4,5009	-33,6089	
g_ronfa	11,5799	-0,6555	-2,1295	-3,7921	7,9940	
g_ebit_a	-3,0869	-0,5782	11,2810	-5,8374	11,7773	
g_roe	-1,0250	-1,5016	29,9331	-8,5135	33,8081	
g_re_ta	-3,2702	0,6126	-10,5087	-4,1045	-11,4362	
v_vol250	2,9200	1,4741	4,1271	3,0302	4,1397	
Curtosis	t_vtas	16,1655	1,0681	113,3682	5,0206	85,2155
	t_vm	43,3089	6,4390	78,0524	5,4124	72,6133
	a_s_ta	5,2785	-0,1899	4,6752	2,0788	5,3267
	a_cf_s	142,0638	0,6374	890,9238	1,7525	1132,2497
	a_vvtas	10,9290	12,5512	13,3745	13,0713	14,2545
	f_cf_td	17,5861	6,3535	384,4536	1,3566	436,7719
	f_ltd_ce	28,6363	1,1024	311,1835	15,2689	395,2125
	f_fa_ce	21,0539	1,8214	598,2428	33,7173	754,8560
	f_td_ta	3,7725	-1,3789	16,1470	31,8164	18,4573
	f_dp_e	16,8891	13,9582	320,5980	17,3178	357,3656
	f_mve_tl	114,2801	5,2484	16,8494	2,3948	160,2964
	f_td_ce	23,0209	0,0274	408,7232	30,2234	515,3957
	l_s_wc	28,0012	1,9861	264,7070	79,2312	237,6058
	l_wc_ltd	120,8188	9,0532	357,4409	82,9099	452,9922
	l_wc_ta	4,9305	0,9100	9,4741	52,6189	23,1105
	l_cl_ta	5,6303	0,7592	25,5721	64,7165	51,4328
	l_quick	48,8658	3,6135	231,1511	18,0441	283,7171
	l_cas_ta	-0,1826	-1,0308	1,5680	2,3521	1,5680
	l_cas_cl	46,9480	4,0964	227,5607	16,6507	278,7986
	l_ca_cl	29,1734	8,9592	203,4407	6,1392	244,9655
l_c_cl	22,7457	2,9738	237,1035	12,8550	298,5285	
l_i_tca	-0,7018	-0,2587	-0,1260	-1,2519	-0,0883	
l_ca_ta	0,1786	-1,2470	-0,4267	0,9079	-0,3268	
l_cl_tl	1,3592	-1,1566	0,6184	1,5483	0,4263	
g_ebit_i	10,2217	2,1533	617,1215	19,6763	769,9545	
g_nia_ta	7,7479	-0,1331	285,0559	26,9735	336,2186	
g_ebit_s	124,4410	-0,4780	896,9177	23,5476	1141,5210	
g_ronfa	137,0661	1,3626	87,2294	16,7898	235,2692	
g_ebit_a	12,7619	-0,0609	265,5591	44,0336	308,6810	
g_roe	22,8586	3,2789	904,6280	76,1549	1154,1381	
g_re_ta	16,3525	-0,7483	142,5465	19,3715	172,3486	
v_vol250	11,7799	4,5810	28,9111	10,3048	29,8427	

Tabla A 22. Estadísticos de las variables agrupadas por sector industrial

		Sector Industrial									Sin agrupar
		Resources	Basic Industries	General Industrials	Cyclical Consumer Goods	Non-Cyclical Consumer Goods	Cyclical Services	Non-Cyclical Services	Utilities	Information Technology	
Rango	t_vtas	91684992	27535404	130715431	186031595	62178416	244523984	97287514	43534570	81169348	244523984
	t_vm	71009116	27105811	242766835	109769664	188374415	221989464	147317123	27980227	277054513	277060035
	a_s_ta	5,0307	3,4032	1,9033	2,8309	4,5343	3,3357	4,2261	1,7491	4,7774	5,0307
	a_cf_s	14,4862	0,4821	0,6683	0,3945	40,2625	338,0128	0,8068	0,4074	3,9633	350,8820
	a_vvtas	3,4827	2,0286	1,7938	0,6556	1,8923	1,8639	2,0122	1,4602	1,3342	3,4827
	f_cf_td	6,8792	0,7763	0,6603	1,5703	1,2074	1,2635	1,0036	0,2015	2,1489	7,9413
	f_ltd_ce	32,9109	31,5491	50,0094	35,1408	173,0496	688,2550	83,8264	55,9532	46,6918	688,2550
	f_fa_ce	52,3560	35,8531	28,6572	36,2147	36,6767	913,8606	126,4281	67,4792	35,0712	949,4178
	f_td_ta	2,7651	1,6132	2,8989	3,6159	1,5066	1,5839	2,9202	0,6135	1,6417	3,8758
	f_dp_e	9,7218	77,0726	25,3228	57,9715	11,5921	6,0133	12,4122	9,0975	9,3590	126,1667
	f_mvte_tl	0,0134	0,0037	0,0059	0,0151	0,0124	0,0452	0,0088	0,0019	0,0179	0,0529
	f_td_ce	51,6002	50,8083	92,0580	94,0769	252,9640	1176,8737	279,4024	107,8717	83,2325	1176,8737
	l_s_wc	715,1940	974,2416	423,6814	1274,1661	1894,2440	2165,9397	1629,8059	3221,6632	3953,3860	5711,3326
	l_wc_ltd	27,7583	2220,7841	14,0187	379,1113	221,0194	25,1692	267,8273	29,8903	2490,7472	4539,3490
	l_wc_ta	2,0202	1,5657	1,1306	0,6859	1,8856	1,4888	2,9436	0,5722	0,8423	3,5088
	l_cl_ta	2,0453	1,2931	0,8850	0,4899	1,3577	1,0715	2,9637	0,4956	0,8923	2,9637
	l_quick	8,0538	11,9386	3,9627	3,1231	41,4002	57,7128	3,6911	1,2200	11,4300	57,7128
	l_cas_ta	0,6155	0,6007	0,5870	0,5784	0,8977	0,8774	0,4638	0,3962	0,8236	0,9228
	l_cas_cl	8,1767	12,1371	4,7738	3,4277	41,8898	58,4521	3,6861	1,3917	11,3215	58,4521
	l_ca_cl	8,4903	14,3737	5,3563	4,9817	41,6836	58,3475	3,6825	1,7025	12,2583	58,4234
l_c_cl	6,8624	10,8284	2,6997	1,1077	41,4611	56,8869	3,5539	0,6267	10,9289	56,8869	
l_i_tca	1,0410	0,9765	0,6413	0,8859	0,7362	0,9486	0,7501	0,4283	0,5465	1,1781	
l_ca_ta	0,6400	0,9244	0,5980	0,6654	0,8448	0,8774	0,7017	0,4085	0,8693	0,9610	
l_cl_tl	0,9116	0,9314	0,7364	1,1088	0,8134	0,9858	0,9746	0,6030	1,1396	1,4415	
g_ebit_i	46,3832	79,1839	61,0822	355,6962	71,2269	90,2964	62,2548	13,7604	987,0787	990,7802	
g_nia_ta	0,9045	1,1105	0,6515	2,0651	1,5013	1,9589	8,6763	0,3715	1,7473	8,6763	
g_ebit_s	18,8567	0,8464	1,3799	2,4713	62,3339	582,8482	6,5980	0,9548	13,5385	595,4886	
g_ronfa	62,4747	25,4584	4,3574	38,7296	15,7907	15,7363	20,4479	0,7934	18,4341	98,2852	
g_ebit_a	0,9561	0,9144	0,5098	1,4775	1,5226	1,9563	8,4496	0,3806	1,9363	8,4496	
g_roe	4,6789	8,7830	8,1858	6,9791	23,6206	158,8548	1794,9240	10,6461	18,3481	1926,3964	
g_re_ta	4,4421	2,4670	3,5962	6,0875	4,0779	4,8281	4,1786	0,6692	21,5571	23,4963	
v_vol250	327,1100	400,6800	151,8100	235,5700	174,6300	193,9600	530,2600	375,2600	221,2800	551,1800	
Media	t_vtas	4218550	3379783	7903986	11762061	7326549	5577958	9757036	5066906	5745332	6330110
	t_vm	4492514	2068503	6914511	4672172	14202394	5556944	9513586	3785742	8407636	6592571
	a_s_ta	0,6170	0,9867	1,0041	1,3520	1,1239	0,9816	1,1802	0,4638	0,8483	0,9558
	a_cf_s	0,5054	0,0727	0,0654	0,0777	-0,1761	-1,1589	0,0975	0,1816	-0,0158	-0,1923
	a_vvtas	0,0034	0,0276	0,0093	0,0113	0,0745	0,0329	0,1174	-0,1657	-0,1216	0,0073
	f_cf_td	0,2519	0,1031	0,1055	0,1331	0,1930	0,1524	0,1219	0,1048	0,0820	0,1420
	f_ltd_ce	0,5196	1,5852	0,5832	1,3950	1,8105	6,8291	0,0130	0,9177	0,8717	2,3397
	f_fa_ce	1,3072	1,7059	0,5697	1,1616	0,6697	7,9832	1,9191	1,9968	0,2328	2,6937
	f_td_ta	0,6465	0,7124	0,7118	0,7014	0,6530	0,7027	0,8330	0,7330	0,5841	0,6945
	f_dp_e	0,2138	-0,5426	0,5772	0,8804	0,1940	0,0953	0,2225	0,4766	-0,0805	0,1591
	f_mvte_tl	0,0015	0,0007	0,0011	0,0009	0,0024	0,0013	0,0007	0,0005	0,0021	0,0013
	f_td_ce	0,9286	2,8681	1,9011	3,4505	2,5263	10,5744	1,7906	2,2358	1,3808	4,0454
	l_s_wc	-9,3228	12,2103	6,7000	5,1085	15,8444	-0,5507	-19,0719	-66,2338	-34,5689	-6,1978
	l_wc_ltd	0,0730	-10,6638	0,9870	5,5482	1,5769	0,4691	-4,6327	-0,4547	42,1181	2,7395
	l_wc_ta	0,0352	0,1515	0,1643	0,1905	0,1495	0,0631	-0,0997	-0,0463	0,2768	0,1012
	l_cl_ta	0,1792	0,2415	0,2889	0,2964	0,2496	0,2304	0,3516	0,2092	0,2633	0,2504
	l_quick	1,1503	0,9750	1,0065	0,9474	1,7395	1,1297	0,7406	0,5404	2,3409	1,1992
	l_cas_ta	0,1708	0,2140	0,3066	0,2892	0,2869	0,2136	0,1850	0,1408	0,4768	0,2498
	l_cas_cl	1,2585	1,0713	1,1823	1,1110	1,9080	1,2795	0,8316	0,6988	2,5617	1,3460
	l_ca_cl	1,5371	1,9939	1,7549	1,8805	2,3841	1,6087	1,0646	0,8258	2,8503	1,7983
l_c_cl	0,4325	0,3437	0,3239	0,2895	1,0801	0,6326	0,3874	0,1555	1,7768	0,6247	
l_i_tca	0,1748	0,4196	0,3245	0,3923	0,2833	0,2075	0,2005	0,1605	0,1178	0,2562	
l_ca_ta	0,2144	0,3931	0,4532	0,4869	0,3991	0,2935	0,2519	0,1629	0,5400	0,3515	
l_cl_tl	0,2670	0,3415	0,4271	0,4402	0,3979	0,3452	0,4000	0,2852	0,4865	0,3710	
g_ebit_i	1,6260	0,8044	0,6957	1,0734	4,6986	2,3016	-1,3593	0,6183	-12,7135	0,3782	
g_nia_ta	0,0535	0,0374	0,0426	0,0716	0,1104	0,0660	0,0190	0,0459	-0,0965	0,0453	
g_ebit_s	0,1184	-0,0064	-0,0092	-0,0027	-0,4005	-2,2348	-0,2266	0,0158	-0,4248	-0,5976	
g_ronfa	0,5727	0,7492	-0,0184	-0,2523	0,3048	-0,0203	0,0150	0,0086	-1,3516	0,0502	
g_ebit_a	0,0057	-0,0019	-0,0011	0,0209	0,0573	0,0111	-0,0483	0,0092	-0,1471	-0,0046	
g_roe	-0,0031	-0,0579	-0,0205	0,1055	0,2627	-0,7604	20,7331	0,1487	-0,2527	1,4046	
g_re_ta	-0,0483	0,1029	0,1426	0,1288	0,1422	0,0296	-0,3421	0,0888	-0,9438	-0,0458	
v_vol250	47,0666	56,4606	51,5186	53,5543	46,5666	54,3928	95,8830	48,1097	87,9142	58,1245	

... continúa

continuación...

				General	Cyclical	Non-Cyclical	Cyclical	Non-Cyclical	Utilities	Information	Sin agrupar
		Resources	Basic Industries	Industrials	Consumer Goods	Consumer Goods	Services	Services		Technology	
Desv. tip.	t_vtas	10888083	4582669	17603012	31350323	11905238	16726926	15320323	6372984	13171951	15344957
	t_vm	8630405	3530560	23699049	13911936	30071623	16415007	25224083	4746887	31100510	20090031
	a_s_ta	0,6277	0,5011	0,3454	0,5596	0,7894	0,7021	1,0301	0,2579	0,7521	0,6931
	a_cf_s	1,8483	0,0694	0,0726	0,0585	3,2455	20,8161	0,1519	0,0803	0,4171	9,9244
	a_vvtas	0,4143	0,2280	0,2179	0,1087	0,2150	0,1665	0,3459	0,3007	0,2300	0,2592
	f_cf_td	0,6366	0,1006	0,0926	0,1632	0,1669	0,1416	0,1451	0,0439	0,2698	0,2469
	f_ltd_ce	3,4188	3,3048	4,2314	4,2648	13,3821	51,8384	9,5127	5,3776	4,2030	25,3998
	f_fa_ce	4,5972	3,0817	2,2298	3,7757	3,1431	60,8143	12,5321	6,2629	3,1926	29,2306
	f_td_ta	0,3476	0,2314	0,3188	0,3593	0,2394	0,2385	0,4306	0,1038	0,2761	0,2869
	f_dp_e	0,8882	5,9793	2,8583	6,3120	0,7438	0,4557	1,2726	0,9154	0,8396	3,0070
	f_mve_tl	0,0017	0,0006	0,0010	0,0015	0,0025	0,0030	0,0012	0,0004	0,0028	0,0021
	f_td_ce	5,2697	5,3184	8,5584	11,4002	18,4561	79,1591	25,4424	10,3465	7,3008	39,2323
	l_s_wc	77,8297	73,6327	37,4715	110,1290	146,1993	138,4392	157,7508	366,9467	382,2818	188,8846
	l_wc_ltd	2,2594	163,9465	1,7375	41,2137	14,4829	2,1033	29,9290	3,0056	269,6883	102,4156
	l_wc_ta	0,1895	0,2190	0,1496	0,1714	0,1998	0,1701	0,4084	0,0862	0,2043	0,2291
	l_cl_ta	0,2179	0,1710	0,1199	0,1078	0,1497	0,1502	0,4026	0,0963	0,1654	0,1889
	l_quick	1,2237	1,0351	0,5324	0,5008	4,4211	3,6206	0,6290	0,2486	2,1368	2,5390
	l_cas_ta	0,1183	0,1260	0,1128	0,1144	0,1613	0,1558	0,1073	0,0846	0,1856	0,1628
	l_cas_cl	1,2277	1,0404	0,6014	0,5969	4,4572	3,7121	0,6406	0,2887	2,1935	2,5797
	l_ca_cl	1,2874	1,6812	0,7859	0,9544	4,4024	3,6648	0,6608	0,3227	2,3111	2,6339
l_c_cl	0,9061	0,9109	0,4265	0,2731	4,4923	3,5730	0,5500	0,1466	2,1316	2,5054	
l_i_tca	0,1809	0,1905	0,1338	0,1852	0,1874	0,2379	0,2479	0,1055	0,1139	0,2126	
l_ca_ta	0,1421	0,2089	0,1314	0,1451	0,1743	0,2055	0,1487	0,0860	0,1973	0,2055	
l_cl_tl	0,1555	0,1815	0,1429	0,1790	0,1883	0,2109	0,2327	0,1210	0,2562	0,2011	
g_ebit_i	5,4622	5,9906	6,9579	29,1399	8,9207	8,3114	7,2446	2,1508	87,7937	28,0705	
g_nia_ta	0,1005	0,1020	0,0923	0,1820	0,1386	0,1397	0,8748	0,0559	0,2596	0,2791	
g_ebit_s	1,4278	0,1002	0,1577	0,2523	5,0003	35,9526	0,8512	0,1376	1,3941	17,1121	
g_ronfa	5,8685	3,2116	0,6266	4,1040	1,2908	1,1180	2,2263	0,1108	3,0156	2,7870	
g_ebit_a	0,1087	0,0910	0,0934	0,1379	0,1326	0,1343	0,8593	0,0518	0,2972	0,2760	
g_roe	0,4689	0,7617	0,8056	0,6383	1,7218	9,7833	189,9160	1,0018	1,7957	52,2290	
g_re_ta	0,6809	0,3333	0,4239	0,6513	0,4605	0,4667	0,8297	0,1104	3,2818	1,1391	
v_vol250	34,1967	44,0253	26,0355	31,3132	26,4992	29,1953	86,8628	51,4631	34,4747	43,3470	
Asimetría	t_vtas	5,8056	3,0709	5,1735	4,2804	2,5684	11,5366	2,9470	3,0743	3,8071	7,7152
	t_vm	5,0940	3,9435	8,9567	6,0180	3,3781	9,6798	4,3444	2,3753	7,0227	7,5600
	a_s_ta	3,9294	2,2399	0,4464	0,9769	2,1410	0,9352	1,1955	3,1722	3,1099	1,8823
	a_cf_s	7,1339	-0,5227	-4,0483	2,4981	-12,1281	-16,1855	-0,5198	0,6920	-5,6812	-33,3996
	a_vvtas	2,0858	1,8455	2,2465	-0,6843	1,2535	2,3576	2,7350	-0,8653	0,0660	1,6064
	f_cf_td	9,7361	-0,1035	-0,6790	-3,3783	-0,3194	1,9395	1,0527	0,2888	-0,4340	16,2549
	f_ltd_ce	-5,8779	3,0492	-4,7656	2,7591	9,0001	9,4591	-2,6314	-8,6981	5,8462	18,4789
	f_fa_ce	-7,0732	5,6416	-4,5159	3,4718	1,3270	12,6737	5,7913	-8,3139	-8,6765	25,8352
	f_td_ta	4,2116	2,4804	4,6836	2,6408	1,2839	1,0456	2,5068	1,0573	1,3957	2,9009
	f_dp_e	-0,0535	-9,9609	7,1468	9,0183	5,3931	1,6130	8,9457	-1,2127	-9,8943	-4,3631
	f_mve_tl	4,1027	1,6562	2,1761	-0,9708	1,8366	12,4572	4,4332	0,9671	3,1227	9,1891
	f_td_ce	-5,9316	1,3957	-2,3420	3,6253	7,1338	10,9123	4,5065	-8,2141	1,3390	20,5055
	l_s_wc	-3,5872	9,4924	-2,4590	-5,3932	11,6794	-0,3273	-5,8866	-7,0759	-10,2891	-11,6755
	l_wc_ltd	-8,3933	-12,3956	3,4802	9,0651	10,1074	4,3601	-8,2446	-9,5704	8,0985	6,6137
	l_wc_ta	-5,4339	-0,1723	-0,2583	0,3620	-0,2912	0,5176	-3,6078	-2,2333	0,4831	-2,1497
	l_cl_ta	6,4846	3,2022	2,0511	0,3943	3,1412	1,3036	4,1128	1,5406	1,2817	5,0409
	l_quick	4,1508	8,1982	2,6203	1,2892	7,2293	15,1152	2,3349	0,6470	2,5236	15,0767
	l_cas_ta	1,4680	1,2382	0,9667	0,5057	1,4956	1,2961	1,0603	1,6924	0,2377	1,2005
	l_cas_cl	4,2232	8,1094	2,8911	1,3731	7,1924	14,9010	2,0485	0,2771	2,4320	14,8875
	l_ca_cl	3,4990	5,2568	2,1626	1,4655	7,1470	14,7962	1,2867	0,2851	2,3839	13,5793
l_c_cl	4,8526	9,8638	3,2978	1,1769	7,2968	15,4317	3,3609	1,3149	2,3781	15,7035	
l_i_tca	0,9964	0,5457	-0,2541	0,4137	0,4846	1,2213	0,9756	0,6603	1,1744	0,7262	
l_ca_ta	1,0038	1,0134	0,5079	0,2830	0,6724	0,6611	0,9744	1,4169	-0,1018	0,5549	
l_cl_tl	1,3991	1,3263	0,3711	-0,6608	0,4712	0,6164	0,9027	1,3149	0,4537	0,7609	
g_ebit_i	3,1329	-1,1400	-1,1556	-4,9537	1,3921	3,5626	-0,2619	-1,2439	-9,0828	-25,1534	
g_nia_ta	0,8022	-1,7323	-1,5901	-5,2737	2,5496	2,4041	6,0146	-2,6818	-1,5453	13,0469	
g_ebit_s	7,4004	-3,4510	-5,3058	-8,6051	-12,2138	-16,1854	0,2716	-2,8585	-6,1805	-33,6089	
g_ronfa	10,4191	4,8606	-3,3956	-9,0001	4,1144	-3,5698	6,4985	-3,7134	-2,3382	7,9940	
g_ebit_a	-2,7633	-2,6359	-2,5328	-5,9421	3,3412	2,1662	5,6961	-3,1790	-2,1305	11,7773	
g_roe	-3,6809	-6,0798	-5,2319	2,8410	-2,5609	-12,8839	9,3771	8,1707	-4,0560	33,8081	
g_re_ta	-4,0986	-1,4664	-1,7673	-2,5308	-2,8078	-3,3344	-1,7460	-0,3949	-4,4392	-11,4362	
v_vol250	5,4175	4,5345	2,0055	4,2316	2,3560	2,4315	2,9037	3,7663	0,7485	4,1397	

... continúa

continuación...

		Resources	Basic Industries	General Industrials	Cyclical Consumer Goods	Non-Cyclical Consumer Goods	Cyclical Services	Non-Cyclical Services	Utilities	Information Technology	Sin agrupar
Curtosis	t_vtas	40,5322	10,7264	30,5663	18,9437	6,6223	160,3852	12,0028	14,0733	15,8953	85,2155
	t_vm	33,7807	20,2006	88,5870	41,6498	12,6819	118,7777	19,9360	7,5040	55,9578	72,6133
	a_s_ta	22,6508	7,4869	0,9690	1,2764	5,4998	0,2832	0,5986	13,8665	12,6161	5,3267
	a_cf_s	50,5520	2,2268	27,3335	10,7606	148,7832	261,9805	1,0861	0,5317	43,7042	1132,2497
	a_vvtas	12,5183	9,5294	11,1922	1,5633	6,9555	20,6364	8,6252	0,2146	0,8254	14,2545
	f_cf_td	99,8893	2,6884	3,6888	26,1703	2,4520	8,2635	4,2391	-0,3090	5,3981	436,7719
	f_ltd_ce	40,8991	15,8309	40,4013	13,7966	97,6856	98,0227	16,4884	81,1151	49,2095	395,2125
	f_fa_ce	61,5219	48,6095	47,3589	22,8348	21,6819	177,1629	46,2097	76,3891	84,7414	754,8560
	f_td_ta	22,0155	9,0540	33,5008	20,5103	3,8003	1,8745	9,5588	2,7384	3,0147	18,4573
	f_dp_e	16,4994	109,2466	51,8675	81,8373	71,4809	21,0756	82,4624	13,6381	100,4701	357,3656
	f_mv_e_tl	24,8028	4,2643	6,6693	16,2727	3,3833	182,2944	25,5181	1,3526	12,3585	160,2964
	f_td_ce	41,3779	11,1762	24,6109	18,2415	78,0026	135,6469	40,9472	74,9690	22,5158	515,3957
	l_s_wc	19,8832	107,2624	25,5722	49,6330	141,6823	38,9137	43,7210	54,4328	105,9099	237,6058
	l_wc_ltd	83,9343	155,2136	15,1333	82,4269	122,2086	32,1496	71,4095	92,6491	69,9503	452,9922
	l_wc_ta	48,0545	4,1628	3,2465	-0,8359	8,0940	2,9702	17,2359	8,8473	-0,4372	23,1105
	l_cl_ta	53,3080	14,7529	8,1159	-0,1520	20,3855	3,6066	21,8786	2,6182	2,1273	51,4328
	l_quick	19,8647	84,4825	11,3639	4,1165	55,5391	236,8065	7,8703	-0,0259	7,2677	283,7171
	l_cas_ta	2,0861	1,3460	0,9347	0,2733	2,9594	1,9331	0,6929	2,7961	-0,3893	1,5680
	l_cas_cl	20,4834	83,9543	14,5340	3,6650	55,2816	230,2151	6,3242	-0,4500	6,6583	278,7986
	l_ca_cl	15,1085	35,6941	7,7712	2,8087	54,9946	230,1531	3,3073	0,0191	6,3895	244,9655
	l_c_cl	28,0458	111,3943	13,9156	0,8500	56,0597	243,6588	14,6631	0,9484	6,3467	298,5285
	l_i_tca	0,8015	0,6466	-0,2189	-0,0288	-0,5606	0,4716	-0,7577	-0,0672	1,4144	-0,0883
	l_ca_ta	0,2638	0,3436	-0,1311	-0,4859	0,3202	-0,5185	0,6364	2,0024	-0,4716	-0,3268
	l_cl_tl	2,8803	2,1349	0,0241	2,0967	-0,3194	-0,3968	0,3108	1,9005	-0,5179	0,4263
	g_ebit_i	17,7179	27,5154	9,2944	51,0794	5,4420	22,3918	7,3592	4,1229	89,1399	769,9545
	g_nia_ta	9,0469	12,9143	5,1091	46,8198	23,2657	32,4718	47,8181	9,6538	4,1770	336,2186
	g_ebit_s	76,2671	18,4842	35,1020	76,8678	150,3136	261,9777	6,5076	10,2477	46,0427	1141,5210
	g_ronfa	108,7040	25,2207	14,4677	81,6542	40,7195	32,4173	48,7094	16,9145	6,0976	235,2692
	g_ebit_a	15,1332	14,2157	7,1518	49,2163	31,0914	36,5711	45,3670	13,5559	5,5844	308,6810
	g_roe	22,7219	48,7146	36,1242	30,6801	38,0783	183,0522	87,9521	75,2065	31,9736	1154,1381
	g_re_ta	18,1408	5,3312	9,2089	16,4936	16,4375	21,1346	2,8724	1,5268	21,0698	172,3486
	v_vol250	41,3376	29,9426	4,6143	24,8752	7,3841	7,4101	11,3785	18,6708	1,6121	29,8427

Tabla A 23. Rangos de las variables de la muestra agrupadas por sector industrial

variable	sin agrupar	BASIC	CYCGD	CYSER	GENIN	ITECH	NCYCG	NCYSR	RESOR	UTILS
t_vtas	244.520.416	27.535.404	186.031.595	244.517.831	130.715.431	81.169.348	62.178.416	97.287.514	91.666.330	23.310.833
t_vm	242.766.819	27.105.811	109.769.348	221.987.426	242.764.857	133.477.809	188.374.415	147.317.122	71.001.338	17.487.864
a_cf-s	53,86	0,48	0,39	1,53	0,67	3,89	40,26	0,81	14,49	0,41
a_s-ta	4,84	3,40	2,50	3,30	1,88	4,78	4,53	4,23	2,87	1,75
a_vvtas	3,48	1,85	0,66	1,86	1,79	1,33	1,89	2,01	3,48	1,46
f_cf-td	7,94	0,78	1,57	0,97	0,66	1,99	1,21	1,00	6,88	0,20
f_ltd-ce	688,26	31,55	35,14	688,26	36,48	19,02	173,05	63,51	32,91	55,95
f_fa-ce	949,42	35,85	36,21	906,16	16,26	7,10	36,68	59,39	52,36	67,48
f_td-ta	3,09	1,61	2,23	1,39	1,29	1,56	1,45	2,28	1,61	0,61
f_mve-tl	0,02	0,00	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,00
f_dp-e	126,17	77,07	57,97	4,18	25,32	9,36	5,07	12,41	9,72	9,10
f_td-ce	1176,87	50,81	94,08	1176,87	92,06	42,96	252,96	123,73	51,60	107,87
l_s-wc	5711,33	974,24	1274,17	2165,94	423,68	3953,39	1894,24	1629,81	504,82	3221,66
l_wc-ltd	4539,35	2220,78	23,81	25,17	14,02	2490,75	221,02	67,42	8,40	29,89
l_wc-ta	2,36	1,57	0,69	1,49	1,13	0,84	1,16	1,80	0,72	0,57
l_cas-ta	0,92	0,59	0,58	0,88	0,55	0,77	0,90	0,45	0,47	0,40
l_ca-ta	0,96	0,92	0,67	0,88	0,60	0,82	0,84	0,68	0,54	0,41
l_cl-tl	1,27	0,87	1,11	0,99	0,63	0,90	0,81	0,86	0,60	0,60
l_cl-ta	1,81	1,29	0,49	1,07	0,89	0,88	0,60	1,78	0,69	0,50
l_quick	57,71	11,91	3,12	57,71	3,96	11,43	41,30	3,27	8,05	1,22
l_cas-cl	58,45	12,11	3,43	58,45	4,77	11,32	41,76	3,33	8,18	1,39
l_ca-cl	58,42	14,37	4,98	58,35	5,36	12,26	41,52	3,32	8,28	1,70
l_c-cl	56,89	10,83	1,11	56,89	2,70	10,93	41,46	2,65	6,86	0,63
l_i-tca	0,95	0,95	0,89	0,95	0,63	0,55	0,74	0,75	0,84	0,43
g_ebit-i	990,78	66,16	355,70	90,30	61,08	987,08	64,58	43,40	46,38	13,76
g_nia-ta	2,40	1,11	2,07	1,10	0,65	1,75	0,91	1,98	0,90	0,37
g_ebit-a	2,29	0,91	1,48	0,97	0,51	1,94	0,93	2,11	0,96	0,38
g_ebit-s	75,12	0,85	2,47	2,33	1,38	13,54	61,88	3,87	18,86	0,95
g_ronfa	98,29	25,46	38,73	15,74	4,36	17,31	15,79	3,82	62,47	0,79
g_roe	155,95	8,78	6,98	155,95	7,48	8,12	23,62	21,41	4,03	10,65
g_re-ta	23,50	2,47	6,09	4,83	3,43	21,56	4,08	4,18	3,26	0,67
v_vol250	546,35	400,68	235,57	193,96	151,81	193,81	174,63	530,26	108,61	368,01

Figura A 22. Rangos de las variables de la muestra con y sin agrupación por sector industrial

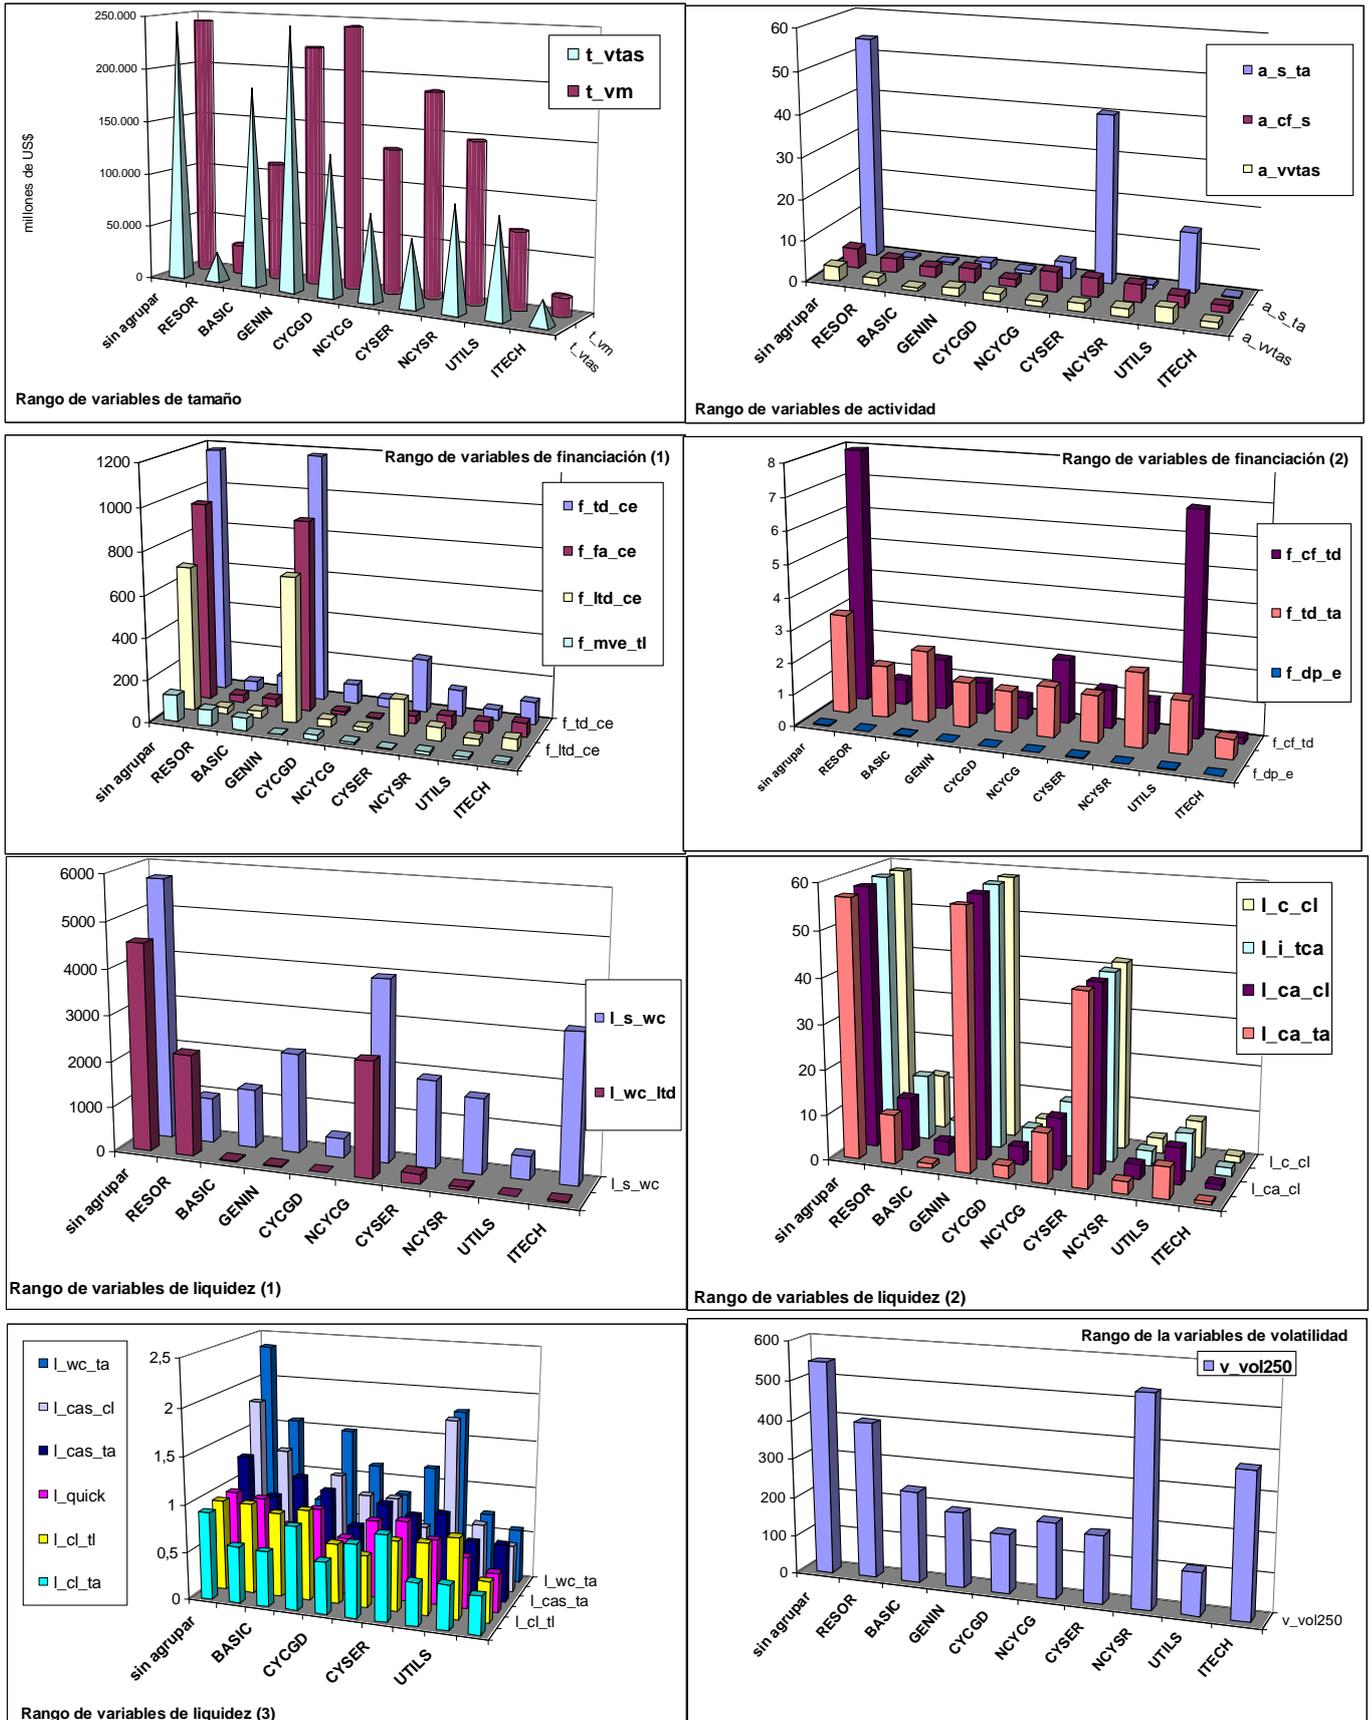


Tabla A 24. Detalles de las características de los valores extremos por sector industrial y grupos de variables

variables → Industria ↓	tamaño	actividad	endeudamiento	liquidez	rentabilidad	volatilidad
BASIC	Casi no existen V.E. y son de poca magnitud	Pocos V.E., y los que hay pertenecen a a_vvtas	Es el grupo de variables de mayor N° de V.E., (la mayoría en el subsector FSTPA) y dos casos resaltan en f_dp_e (Officemax y Meadwestvaco)	Algunos V.E. El que más resalta es un caso en l_wc_ltd (Viskase Co.). Los restantes V.E. son moderados.	La mayoría de los V.E. están el subsector CNSBM, aunque son de relativa pequeña magnitud	Pocos V.E., destacando el valor observado en Viskase Co.
CYCGD	Pocos V.E., pero los hay de gran volumen (GM, Ford, Toyota, DaimlerCrysler)	Prácticamente no hay V.E.	Muchos V.E. pero de poca magnitud, salvo en f_dp_e (Steelcase)	La mayoría de los V.E. están en las variables l_wc_ltd, l_wc_ta y l_cl_ta. Los casos más relevantes son Wamaco Gp., Gemstar TVG y GKN	Casi el 90% de los V.E. se encuentran en el subsector HHOLD. La mayoría tiene valores relativamente pequeños, salvo Gemstar TVG y Ethan Allen.	Sólo hay un V.E.: Galey & Lord, que es de medio tamaño.
CYSER	Algunos M.E., pero de pequeño tamaño, salvo Wall Mart, el más grande de todos los M.E.	Muy pocos V.E. y de pequeño tamaño, pero una compañía genera dos V.E. de gran magnitud: Sirius Satellite Radio	Muchos V.E. de una amplia gama de valores, aunque se concentran en los subsectores LESUR (Avado Brands, AMC Entrtm.) y MEDIA (Charter Comms.)	Pocos V.E., pero mayoría de los V.E. están en las variables l_wc_ltd, l_s_wc (Rh Donolley, Frenly lcrm, Cadmus Comms.	Muchos V.E. La mayoría de ellos en el subsector MEDIA. Los V.E. más relevantes pertenecen a Sirius Satellite Radio, Avado Brands y Charter Comms.	Muy pocos V.E. y todos ellos son pequeños.
GENIN	Hay un número medio de V.E., aunque de pequeño y mediano tamaño, excepto General Electric, una de las más grandes compañías.	Muy pocos V.E., pero la variable a_vvtas tiene altos valores (Sanmina-Sci, LTX y Shaw Group), poco relevantes comparados con los otros sectores industriales.	Hay un número medio de V.E., aunque no tienen valores significativamente altos. Valhi y Makita tienen los V.E. de mayor tamaño relativo y Thermadyne destaca en la variable f_td-ta, pero tiene poca relevancia global.	Pocos V.E. y de vana relevancia.	Hay un número medio de V.E. de pequeña y mediana magnitud.	Ningún V.E.
ITECH	Hay un reducido número de V.E., y las únicas compañías más relevantes (Microsoft e IBM) están en la variable t_vm.	Pocos V.E. de las cuales sólo Tech Data e Ingram Micro destacan en la variable a_s_ta, pero no tienen gran magnitud.	Pocos V.E., y los que hay son de mediano o pequeño tamaño. Sólo destaca Microsoft en el ratio f_mve_tl.	Muchos V.E. y los de mayor tamaño están en el subsector INFOH. Los V.E. de mayor relevancia pertenecen a Dell, Cirrus Logic, Arris G., Semtech y Earthlink	Hay muchísimos V.E. y la mayoría tiene mediana magnitud, aunque las excepciones pertenecen a Oracle, Cirrus Logic, Transwitch Corp, I2 Tech., Critical Path y Akamai Tech.	Muy pocos V.E. y ellos son pequeños.
NCYCG	Muchos V.E., de los cuales las compañías con mayores ratios son Pfizer, Atria, J&J, Merk, Glaxo S. y Coca-Cola	Muy pocos V.E. pero destacan los ratios de Human Genome Scs. por su magnitud.	Hay un número medio de V.E., y la mayor parte de ellos son pequeños, excepto los de Playtex Products.	La mayor parte de los V.E. están en el subsector PHARM. Los V.E. más relevantes son de Coca-Cola, Protein Design Labs., Human Genome Scs. y Curagen	Un tercio de los V.E. están en el subsector PHARM. Los V.E. de mayor tamaño relativo pertenecen a Human Genome Scs. y a Mariner Hlth.Care.	Sólo hay dos V.E. y son medianos.
NCYSR	Bastantes V.E., de los cuales lo mayores valores provienen de NTT Docomo Inc., Nippon T&T, Vodafone y SBC Comm.	Pocos V.E., pero de gran magnitud, especialmente de compañías del subsector TELCM. Los ratios más grandes son de Airgate PCS, Level 3 Comms., Leap Wrls.	La mayor parte de los V.E. pertenecen a compañías de TELCM, aunque muchos de ellos tienen valores relativamente pequeños. Aunque destacan como V.E. los ratios de Allstream, Metrocall y NTT Docomo Inc.	La mayoría de los V.E. están en las variables l_s_wc, l_wc_ltd, l_wc_ta y l_cl-ta. Los casos más relevantes son de Allstream, Kroger y Focal Comms.	Muchos V.E., y el 95% de ellos está en el sector TELCM. Destacan los ratios de Metrocall y NII Hdg.	De todos los V.E. de esta variable, la mayoría se encuentra en este sector industrial TELCM, destacando los valores de ITC Deltacom, Focal Comms., Worldcom Gp.
RESOR	Pocos V.E. y de tamaño pequeño, excepto ChevronTexaco.	Bastantes V.E. El 97% de ellos están en el subsector OILGS, destacando los ratios de a_vvtas (Plains Resour., Plains All Amer., Elf Aquitaine y Enbridge Energy)	No muchos V.E. y de escaso tamaño. Destacan sólo Friede Goldman y Grant Geophysical por su mayor magnitud.	El 95% de los V.E. están en el subsector OILGS. El único dato extremo que resalta por su magnitud pertenece a Grant Geophysical	Hay algunos V.E. de los cuales destacan los de la compañía Elf Aquitaine.	Sólo se observa un V.E. el que no es significativo.
UTILS	Muy pocos (4) y de poco tamaño.	Lo únicos V.E. son de la variable a_vvtas. Los ratios más grandes de este sector industrial pertenecen a Aquila, Avista y Centerpoint, pero no son los más grandes del total de V.E. de esta variable.	De los V.E. de los ratios de endeudamiento, la mayoría pertenecen al subsector ELECT. Ninguno de ellos tiene gran magnitud.	Pocos V.E. Todos ellos están en los ratios l_s_wc y l_wc_ltd. Los V.E. de mayor magnitud pertenecen a Pacific Nthn.Gs, Kelda, Veolia Environnement y Keyspan.	Pocos V.E. y sólo un de ellos tiene mayor tamaño, pero comparado con otros sectores no es relevante.	Muy pocos (3), pero uno de ellos es relevante (Covanta).

Tabla A 25. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías de Japón

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mv_t	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250
t_vtas	1	0,7	0,225	-0,23	-0,13	-0,22	0,114	<u>0,022</u>	0,206	-0,12	-0,26	0,243	0,317	<u>-0,02</u>	<u>0,003</u>	0,397	<u>-0,01</u>	0,293	<u>-0,01</u>	<u>-0,03</u>	<u>0,052</u>	-0,19	0,163	0,175	<u>-0</u>	-0,13	-0,13	<u>-0,02</u>	-0,11	<u>-0,06</u>	-0,24	0,188
t_vm		1	0,151	<u>-0,08</u>	<u>0,071</u>	<u>-0,03</u>	<u>-0,01</u>	<u>-0</u>	<u>0,046</u>	<u>-0,08</u>	<u>-0,03</u>	<u>0,058</u>	0,317	<u>0,034</u>	<u>0,003</u>	0,298	<u>0,052</u>	0,267	0,113	<u>-0</u>	<u>0,089</u>	-0,25	0,114	0,225	<u>0,095</u>	<u>0,022</u>	<u>-0,03</u>	<u>0,046</u>	<u>0,009</u>	<u>0,034</u>	-0,12	0,249
a_s_ta			1	<u>-0,58</u>	<u>0,009</u>	<u>-0,01</u>	-0,42	-0,41	-0,25	-0,11	0,262	-0,24	0,329	0,378	0,348	0,434	0,36	0,34	0,293	0,378	0,298	0,193	0,422	<u>0,532</u>	0,132	0,108	-0,13	0,145	<u>0,058</u>	<u>-0,08</u>	0,249	0,163
a_cf_s				1	0,194	0,372	0,286	0,391	0,12	0,249	<u>-0,07</u>	<u>0,095</u>	-0,18	-0,37	-0,39	-0,49	-0,28	-0,45	-0,21	-0,37	-0,3	-0,33	<u>-0,59</u>	-0,45	<u>0,071</u>	0,145	0,323	<u>0,058</u>	0,145	0,268	-0,19	-0,23
a_vvtas					1	<u>0,563</u>	-0,31	-0,21	-0,42	0,145	<u>0,522</u>	-0,44	0,237	0,249	0,268	-0,13	0,378	<u>0,093</u>	0,38	0,311	0,268	-0,31	<u>0,046</u>	<u>0,095</u>	0,323	0,335	0,108	0,298	0,286	0,138	0,243	0,169
f_cf_td						1	-0,29	-0,11	-0,46	0,151	<u>0,515</u>	-0,48	0,132	0,157	0,126	-0,29	0,225	-0,15	0,233	0,169	0,126	-0,19	-0,17	<u>-0,03</u>	0,317	0,391	0,163	0,292	0,317	0,169	0,286	<u>0,003</u>
f_ltd_ce							1	<u>0,711</u>	<u>0,735</u>	<u>0,077</u>	<u>-0,64</u>	<u>0,723</u>	-0,16	<u>-0,79</u>	<u>-0,7</u>	<u>-0,07</u>	<u>-0,66</u>	-0,33	<u>-0,64</u>	<u>-0,72</u>	<u>-0,56</u>	-0,18	-0,44	<u>-0,5</u>	-0,13	<u>-0,09</u>	0,126	<u>-0,09</u>	<u>-0,06</u>	0,108	<u>-0,65</u>	-0,17
f_fa_ce								1	<u>0,52</u>	<u>0,095</u>	-0,46	<u>0,532</u>	-0,18	<u>-0,71</u>	<u>-0,72</u>	-0,22	<u>-0,63</u>	-0,49	<u>-0,62</u>	<u>-0,71</u>	<u>-0,61</u>	-0,2	<u>-0,57</u>	-0,5	-0,12	<u>-0,01</u>	0,145	-0,14	<u>-0,02</u>	0,114	<u>-0,51</u>	-0,19
f_td_ta									1	<u>0,022</u>	<u>-0,69</u>	<u>0,938</u>	-0,13	<u>-0,61</u>	<u>-0,62</u>	0,12	<u>-0,67</u>	-0,21	<u>-0,63</u>	<u>-0,64</u>	<u>-0,56</u>	<u>-0,03</u>	-0,27	-0,32	-0,11	-0,11	0,12	<u>-0,06</u>	<u>-0,07</u>	0,102	<u>-0,7</u>	-0,2
f_dp_e										1	<u>0,015</u>	<u>-0,02</u>	<u>-0</u>	-0,1	-0,17	-0,38	-0,14	-0,29	-0,12	-0,14	-0,13	<u>0,007</u>	-0,32	-0,34	<u>0,034</u>	<u>0,083</u>	0,188	<u>-0,02</u>	<u>0,009</u>	0,108	<u>-0,02</u>	-0,29
f_mv_t											1	<u>-0,73</u>	0,151	<u>0,528</u>	0,491	<u>-0,03</u>	<u>0,528</u>	0,154	<u>0,528</u>	<u>0,522</u>	0,404	<u>-0,07</u>	0,225	0,336	0,213	0,256	<u>0,003</u>	0,188	0,201	<u>0,022</u>	<u>0,515</u>	0,133
f_td_ce												1	-0,13	<u>-0,6</u>	<u>-0,59</u>	0,132	<u>-0,66</u>	-0,19	<u>-0,63</u>	<u>-0,62</u>	<u>-0,52</u>	<u>-0,03</u>	-0,25	-0,31	-0,11	-0,12	0,12	<u>-0,06</u>	<u>-0,08</u>	<u>0,089</u>	<u>-0,69</u>	-0,18
l_s_wc													1	0,151	<u>0,046</u>	0,268	0,145	0,16	<u>0,1</u>	<u>0,065</u>	0,182	-0,24	0,12	0,231	<u>0,028</u>	<u>-0,01</u>	-0,19	0,102	<u>0,003</u>	<u>-0,07</u>	<u>0,009</u>	0,28
l_wc_ltd														1	<u>0,846</u>	<u>0,095</u>	<u>0,723</u>	0,447	<u>0,72</u>	<u>0,852</u>	<u>0,686</u>	0,167	<u>0,526</u>	0,465	0,138	<u>0,089</u>	-0,11	0,126	<u>0,065</u>	<u>-0,08</u>	<u>0,575</u>	0,157
l_wc_ta															1	0,114	<u>0,791</u>	<u>0,527</u>	<u>0,773</u>	<u>0,92</u>	<u>0,766</u>	0,153	<u>0,582</u>	0,446	<u>0,071</u>	<u>0,009</u>	-0,18	0,108	<u>-0,02</u>	<u>-0,08</u>	<u>-0,06</u>	0,286
l_cl_ta																1	<u>0,065</u>	<u>0,54</u>	<u>0,053</u>	<u>0,071</u>	<u>-0,02</u>	<u>0,087</u>	<u>0,532</u>	<u>0,557</u>	<u>0,058</u>	<u>-0,08</u>	-0,16	0,108	<u>-0,02</u>	<u>-0,08</u>	<u>-0,06</u>	0,286
l_quick																	1	0,493	<u>0,913</u>	<u>0,822</u>	<u>0,778</u>	<u>-0,01</u>	<u>0,52</u>	0,422	<u>0,071</u>	<u>0,009</u>	-0,21	<u>0,046</u>	<u>-0,04</u>	-0,16	<u>0,52</u>	0,348
l_cas_ta																		1	<u>0,513</u>	0,493	0,387	<u>0,027</u>	<u>0,807</u>	<u>0,587</u>	<u>0,087</u>	<u>-0,09</u>	-0,17	<u>0,06</u>	<u>-0,03</u>	<u>-0,09</u>	0,18	0,333
l_cas_cl																			1	<u>0,807</u>	<u>0,767</u>	<u>-0,05</u>	0,48	0,34	<u>0,093</u>	<u>0,027</u>	-0,17	<u>0,067</u>	<u>-0,01</u>	<u>-0,1</u>	0,493	0,3
l_ca_cl																				1	<u>0,785</u>	0,147	<u>0,538</u>	0,428	<u>0,089</u>	<u>0,04</u>	-0,18	<u>0,065</u>	<u>-0,01</u>	-0,16	<u>0,502</u>	0,255
l_c_cl																					1	<u>0</u>	0,422	0,311	<u>-0,03</u>	<u>-0,09</u>	-0,3	<u>-0,06</u>	<u>-0,14</u>	-0,26	0,422	0,36
l_i_tca																						1	0,22	0,147	<u>-0,03</u>	<u>-0,05</u>	0	<u>-0,02</u>	<u>-0,03</u>	<u>-0,07</u>	0,207	-0,16
l_ca_ta																							1	<u>0,631</u>	<u>0,058</u>	-0,1	-0,21	<u>0,058</u>	<u>-0,05</u>	-0,16	0,298	0,372
l_cl_tl																								1	0,108	<u>-0,02</u>	-0,18	<u>0,058</u>	<u>-0,02</u>	-0,16	0,323	0,286
g_ebit_i																									1	<u>0,729</u>	<u>0,649</u>	<u>0,865</u>	<u>0,828</u>	<u>0,643</u>	0,194	-0,21
g_nia_ta																										1	<u>0,674</u>	<u>0,742</u>	<u>0,84</u>	<u>0,68</u>	0,194	-0,27
g_ebit_s																											1	<u>0,649</u>	<u>0,76</u>	<u>0,809</u>	<u>0,003</u>	-0,45
g_ronfa																												1	<u>0,852</u>	<u>0,68</u>	0,12	-0,2
g_ebit_a																												1	<u>0,778</u>	0,145	-0,3	
g_roe																													1	<u>-0,02</u>	-0,38	
g_re_ta																														1	<u>-0,01</u>	
v_vol250																																1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 26. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías de Europa

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_tl	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,64	0,21	<u>-0,09</u>	<u>0,05</u>	<u>0,03</u>	<u>-0</u>	0,14	0,11	<u>-0,01</u>	<u>0,05</u>	0,13	<u>-0,07</u>	-0,19	-0,2	0,19	-0,22	<u>-0,05</u>	-0,21	-0,19	<u>-0,06</u>	<u>0,08</u>	<u>-0,02</u>	0,17	<u>0,03</u>	<u>0,07</u>	<u>-0,06</u>	<u>0,02</u>	<u>0,04</u>	<u>0,05</u>	0,14	<u>0,01</u>	
t_vm		1	<u>0,04</u>	0,14	<u>0,06</u>	0,2	<u>-0,1</u>	<u>0,05</u>	<u>-0,05</u>	<u>0,08</u>	0,33	<u>-0,04</u>	<u>-0,09</u>	-0,14	-0,14	<u>0,02</u>	-0,16	<u>-0,09</u>	-0,14	-0,14	<u>-0,09</u>	<u>-0,03</u>	<u>-0,09</u>	<u>0,07</u>	<u>0,1</u>	0,14	<u>0,08</u>	<u>0,1</u>	0,15	<u>0,05</u>	0,25	-0,13	
a_s_ta			1	-0,4	<u>0,02</u>	<u>0,06</u>	<u>-0,09</u>	<u>-0,04</u>	0,14	0	<u>0,04</u>	<u>0,09</u>	<u>0,01</u>	<u>0,04</u>	<u>0,04</u>	0,4	<u>0,01</u>	0,26	<u>-0,03</u>	<u>0,04</u>	<u>-0,03</u>	0,27	0,34	0,29	0,19	0,2	0	0,17	0,17	0,23	<u>-0,02</u>	<u>0,03</u>	
a_cf_s				1	<u>0,06</u>	0,48	<u>0,04</u>	<u>0,09</u>	-0,19	0,16	0,25	-0,11	<u>-0,01</u>	<u>-0,05</u>	<u>-0,04</u>	-0,38	<u>-0,02</u>	-0,29	<u>-0,02</u>	<u>-0,04</u>	<u>-0,05</u>	<u>-0,09</u>	-0,31	-0,32	0,17	0,21	0,37	0,15	0,21	<u>-0,01</u>	0,21	-0,29	
a_vvtas					1	<u>0,07</u>	<u>-0,02</u>	<u>0,04</u>	<u>-0</u>	0,1	0,12	<u>-0,05</u>	<u>-0,09</u>	-0,18	-0,2	<u>-0</u>	-0,19	-0,21	-0,21	-0,22	-0,19	<u>-0,02</u>	-0,21	0	0,11	0,12	0,11	0,11	0,12	<u>0,07</u>	<u>0,03</u>	-0,19	
f_cf_td						1	-0,17	<u>-0,01</u>	-0,36	0,19	0,44	-0,22	<u>0,04</u>	<u>0,08</u>	<u>0,1</u>	-0,22	0,12	<u>-0,08</u>	<u>0,09</u>	0,1	<u>-0,04</u>	<u>0,07</u>	<u>-0,07</u>	<u>-0,06</u>	0,41	0,41	0,38	0,32	0,44	0,16	0,34	-0,26	
f_ltd_ce							1	0,42	0,4	<u>-0,02</u>	-0,26	<u>0,64</u>	<u>-0,05</u>	<u>-0,09</u>	<u>-0,07</u>	<u>-0,05</u>	-0,1	<u>-0,09</u>	<u>-0,08</u>	<u>-0,08</u>	<u>0,07</u>	<u>0,01</u>	<u>-0,09</u>	-0,24	-0,11	<u>-0,03</u>	<u>-0,06</u>	<u>-0,04</u>	<u>-0,09</u>	<u>-0,09</u>	-0,2	<u>-0</u>	
f_fa_ce								1	0,14	<u>0,1</u>	-0,16	0,4	-0,11	-0,17	-0,2	-0,15	-0,24	-0,29	-0,21	-0,2	<u>-0,1</u>	<u>0,08</u>	-0,27	-0,21	<u>0,03</u>	<u>0,07</u>	<u>0,07</u>	-0,1	<u>0,05</u>	<u>-0,02</u>	<u>0,04</u>	-0,17	
f_td_ta									1	-0,11	-0,34	<u>0,66</u>	<u>-0,05</u>	-0,22	-0,21	0,38	-0,23	<u>0,09</u>	-0,22	-0,22	<u>-0,09</u>	<u>-0,01</u>	<u>0,08</u>	<u>-0,02</u>	-0,13	<u>-0,08</u>	-0,18	<u>-0,06</u>	-0,14	0,12	-0,36	<u>0,09</u>	
f_dp_e										1	0,17	<u>-0,03</u>	<u>0,04</u>	<u>0,01</u>	<u>-0</u>	<u>-0,05</u>	<u>-0,03</u>	<u>-0,08</u>	<u>-0,05</u>	<u>-0</u>	<u>-0,09</u>	<u>0,08</u>	<u>-0,06</u>	0	0,31	0,3	0,4	0,29	0,31	0,18	0,24	-0,31	
f_mve_tl											1	-0,28	<u>-0,01</u>	0	<u>0,01</u>	<u>-0,09</u>	<u>0,01</u>	<u>-0,06</u>	<u>-0,02</u>	<u>0,01</u>	<u>-0,05</u>	<u>0,02</u>	<u>-0,03</u>	<u>0,08</u>	0,29	0,29	0,3	0,27	0,34	0,12	0,28	-0,27	
f_td_ce												1	<u>-0,05</u>	-0,11	<u>-0,09</u>	0,22	-0,13	<u>0,07</u>	-0,12	<u>-0,09</u>	<u>0,02</u>	<u>0,08</u>	<u>0,08</u>	<u>0,01</u>	<u>-0,02</u>	<u>0,03</u>	<u>-0,07</u>	<u>0,05</u>	<u>-0,02</u>	0	-0,2	<u>0</u>	
l_s_wc													1	0,21	0,16	<u>-0,07</u>	0,15	<u>0,09</u>	0,14	0,12	<u>0,05</u>	0,15	0,15	<u>-0,05</u>	<u>0,03</u>	<u>0,05</u>	<u>0,03</u>	<u>0,04</u>	<u>0,03</u>	<u>0,01</u>	<u>0,06</u>	<u>-0,01</u>	
l_wc_ltd														1	0,86	-0,23	0,61	0,33	0,63	0,81	0,27	0,11	0,41	<u>-0,09</u>	<u>0,1</u>	<u>0,07</u>	<u>0,06</u>	0,11	<u>0,09</u>	<u>-0,02</u>	<u>0,01</u>	<u>0,02</u>	
l_wc_ta															1	-0,21	0,63	0,36	0,66	0,88	0,28	0,13	0,45	<u>-0,08</u>	<u>0,1</u>	<u>0,07</u>	<u>0,06</u>	0,12	<u>0,09</u>	<u>-0,02</u>	<u>0,01</u>	<u>0,05</u>	
l_cl_ta																1	-0,19	0,33	-0,23	-0,23	<u>-0,08</u>	<u>0,08</u>	0,34	0,6	<u>0,04</u>	<u>0,02</u>	<u>-0,09</u>	<u>0,09</u>	<u>-0</u>	0,19	-0,18	0,13	
l_quick																	1	0,46	0,85	0,66	0,45	-0,15	0,36	<u>-0,06</u>	<u>0,08</u>	<u>0,03</u>	<u>0,03</u>	0,1	<u>0,06</u>	<u>-0,04</u>	<u>0,03</u>	<u>0,05</u>	
l_cas_ta																		1	0,43	0,35	0,31	-0,14	0,7	0,33	<u>0,09</u>	<u>0,03</u>	<u>-0,05</u>	0,15	<u>0,05</u>	<u>0,08</u>	-0,14	0,18	
l_cas_cl																			1	0,68	0,47	-0,17	0,33	<u>-0,1</u>	<u>0,04</u>	0	<u>-0</u>	<u>0,06</u>	<u>0,03</u>	<u>-0,06</u>	<u>0,03</u>	<u>0,09</u>	
l_ca_cl																				1	0,29	0,14	0,44	<u>-0,09</u>	<u>0,1</u>	<u>0,08</u>	<u>0,07</u>	0,13	<u>0,09</u>	<u>-0,03</u>	<u>0,02</u>	<u>0,05</u>	
l_c_cl																					1	-0,23	0,18	<u>-0,04</u>	<u>-0,03</u>	<u>-0,05</u>	<u>-0,06</u>	<u>-0,02</u>	<u>-0,06</u>	<u>-0,08</u>	<u>-0,06</u>	0,15	
l_i_tca																						1	0,16	<u>0,04</u>	0,15	0,2	0,14	0,15	0,17	0,1	<u>0,02</u>	<u>-0,06</u>	
l_ca_ta																							1	0,33	0,12	<u>0,08</u>	0	0,19	<u>0,09</u>	0,1	-0,11	0,15	
l_cl_tl																								1	<u>0,09</u>	<u>0,01</u>	<u>-0,07</u>	0,11	<u>0,05</u>	<u>0,1</u>	<u>0,02</u>	0,13	
g_ebit_i																									1	0,7	0,67	0,69	0,78	0,54	0,29	-0,43	
g_nia_ta																										1	0,71	0,7	0,85	0,56	0,29	-0,44	
g_ebit_s																											1	0,61	0,75	0,44	0,31	-0,5	
g_ronfa																												1	0,73	0,5	0,22	-0,34	
g_ebit_a																													1	0,58	0,34	-0,46	
g_roe																														1	<u>0,07</u>	-0,31	
g_re_ta																															1	-0,26	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 27. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías de EUA

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_t	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,57	0,19	0,03	0,09	0,15	<u>-0,01</u>	0,06	<u>-0,02</u>	0,23	0,13	0,11	0,07	<u>-0</u>	<u>-0,07</u>	0,21	-0,18	<u>-0,01</u>	-0,18	-0,14	-0,13	0,14	0,03	0,22	0,25	0,14	0,15	0,19	0,21	0,15	0,28	-0,23	
t_vm		1	<u>-0,06</u>	0,28	0,08	0,31	<u>-0,09</u>	0,03	-0,22	0,29	0,44	<u>-0,02</u>	<u>-0,01</u>	0,01	<u>-0,05</u>	0,01	<u>-0,03</u>	<u>-0,01</u>	<u>-0,02</u>	<u>-0,06</u>	0,01	<u>-0,02</u>	<u>-0,05</u>	0,12	0,37	0,23	0,33	0,27	0,32	0,16	0,36	-0,38	
a_s_ta			1	-0,33	0,13	0,15	<u>-0,05</u>	<u>-0,08</u>	0,04	0,01	0,05	0,02	0,22	0,19	0,18	0,43	-0,11	0,2	-0,13	0,06	-0,14	0,38	0,39	0,38	0,18	0,24	<u>-0,01</u>	0,2	0,2	0,15	0,16	<u>-0,05</u>	
a_cf_s				1	0,03	0,46	0,02	0,13	-0,16	0,18	0,24	<u>-0,03</u>	<u>-0,08</u>	-0,16	-0,17	-0,28	0,02	-0,2	0,03	-0,1	0,01	-0,22	-0,31	-0,19	0,28	0,26	0,47	0,23	0,29	0,12	0,19	-0,26	
a_vvtas					1	0,16	<u>-0</u>	<u>-0,06</u>	<u>-0,04</u>	<u>-0,02</u>	0,1	<u>-0,01</u>	0,05	0,04	0,04	<u>-0,01</u>	<u>-0,02</u>	<u>-0,05</u>	<u>-0,03</u>	0,05	<u>-0,01</u>	0,08	0,02	0,02	0,18	0,21	0,13	0,21	0,2	0,13	0,06	<u>-0,06</u>	
f_cf_td						1	-0,16	<u>-0,02</u>	-0,39	0,19	0,52	-0,18	0,04	0,11	0,07	<u>-0,04</u>	0,04	<u>-0</u>	0,05	0,07	0,02	0,04	0,01	0,16	0,54	0,5	0,47	0,45	0,55	0,24	0,4	-0,3	
f_ltd_ce							1	0,58	0,36	0,06	-0,28	0,75	0,02	-0,24	-0,12	-0,1	-0,11	-0,18	-0,1	-0,11	-0,12	0,04	-0,17	-0,24	-0,11	<u>-0</u>	0,02	<u>-0,03</u>	<u>-0,03</u>	-0,1	<u>-0,09</u>	<u>-0,04</u>	
f_fa_ce								1	0,19	0,14	-0,16	0,58	0,05	-0,31	-0,29	-0,12	-0,21	-0,3	-0,21	-0,26	-0,16	0,01	-0,33	-0,19	<u>-0,02</u>	<u>-0</u>	0,06	-0,14	<u>0</u>	-0,11	<u>0</u>	-0,15	
f_td_ta									1	<u>-0,04</u>	<u>-0,5</u>	0,58	0,02	-0,36	-0,29	0,21	-0,28	<u>-0,08</u>	-0,28	-0,32	-0,19	<u>-0</u>	<u>-0,1</u>	-0,15	-0,25	-0,12	-0,19	-0,17	-0,21	0,1	-0,31	0,11	
f_dp_e										1	0,16	0,1	0,04	<u>-0,08</u>	-0,1	0,03	-0,12	<u>-0,09</u>	-0,13	-0,12	-0,13	0,08	<u>-0,08</u>	0,05	0,32	0,24	0,33	0,24	0,28	0,19	0,27	-0,4	
f_mve_t											1	-0,29	0,01	0,26	0,2	<u>-0,05</u>	0,19	0,14	0,2	0,21	0,17	<u>-0</u>	0,13	0,19	0,44	0,34	0,35	0,35	0,42	0,13	0,38	-0,29	
f_td_ce												1	0,06	-0,22	-0,18	0,06	-0,2	-0,13	-0,2	-0,2	-0,18	0,07	-0,12	<u>-0,08</u>	<u>-0,04</u>	<u>0</u>	0,01	0,01	<u>-0,01</u>	<u>-0,06</u>	<u>-0,05</u>	<u>-0,08</u>	
l_s_wc													1	0,07	<u>-0</u>	0,05	<u>-0,02</u>	<u>-0,01</u>	<u>-0,02</u>	<u>-0,07</u>	<u>-0,07</u>	0,15	0,05	0,01	0,05	0,07	<u>0</u>	0,06	0,06	0,01	0,09	<u>-0,05</u>	
l_wc_ltd														1	0,8	0,03	0,44	0,42	0,45	0,68	0,31	0,19	0,55	0,22	0,07	0,03	<u>-0,03</u>	0,11	0,06	<u>-0,07</u>	0,16	0,07	
l_wc_ta															1	<u>-0,02</u>	0,51	0,44	0,51	0,79	0,34	0,18	0,58	0,11	0,02	0,02	<u>-0,04</u>	0,1	0,04	<u>-0,08</u>	0,11	0,11	
l_cl_ta																1	-0,25	0,33	-0,25	-0,19	-0,17	0,16	0,4	0,64	0,06	0,06	<u>-0,08</u>	0,09	0,05	0,15	0,04	0,03	
l_quick																	1	0,41	0,88	0,61	0,52	-0,24	0,24	-0,11	<u>-0,05</u>	<u>-0,07</u>	<u>-0,03</u>	<u>-0,01</u>	<u>-0,05</u>	-0,13	<u>-0</u>	0,12	
l_cas_ta																		1	0,42	0,33	0,31	-0,13	0,66	0,37	<u>-0,01</u>	<u>-0,05</u>	-0,11	0,04	<u>-0,03</u>	<u>-0,01</u>	0,01	0,15	
l_cas_cl																			1	0,62	0,5	-0,25	0,23	-0,11	<u>-0,05</u>	<u>-0,07</u>	<u>-0,03</u>	<u>-0,02</u>	<u>-0,06</u>	-0,13	<u>0</u>	0,12	
l_ca_cl																				1	0,39	0,13	0,42	<u>-0,02</u>	0,01	0,01	<u>-0,03</u>	0,08	0,03	-0,1	0,1	0,11	
l_c_cl																					1	-0,22	0,19	<u>-0,05</u>	<u>-0,05</u>	<u>-0,07</u>	<u>-0,05</u>	<u>-0,05</u>	<u>-0,05</u>	<u>-0,09</u>	<u>-0,06</u>	0,16	
l_i_tca																						1	0,21	0,16	0,11	0,15	0,02	0,14	0,13	0,04	0,19	-0,1	
l_ca_ta																							1	0,45	0,04	0,03	<u>-0,09</u>	0,12	0,05	0,02	0,08	0,12	
l_cl_tl																								1	0,19	0,1	0,01	0,18	0,14	0,09	0,18	<u>-0,02</u>	
g_ebit_i																									1	0,67	0,7	0,74	0,81	0,46	0,46	-0,42	
g_nia_ta																										1	0,63	0,69	0,8	0,49	0,38	-0,37	
g_ebit_s																											1	0,65	0,74	0,42	0,38	-0,44	
g_ronfa																												1	0,78	0,45	0,4	-0,35	
g_ebit_a																													1	0,54	0,46	-0,42	
g_roe																														1	0,18	-0,21	
g_re_ta																															1	-0,42	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 28. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías de Canadá.

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_t	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,6	0,22	<u>-0</u>	<u>-0,03</u>	0,16	-0,14	<u>-0,03</u>	-0,16	0,14	0,16	<u>-0,04</u>	0,09	<u>-0,01</u>	<u>-0,05</u>	0,09	<u>-0,1</u>	<u>-0,03</u>	<u>-0,07</u>	<u>-0,05</u>	<u>-0,06</u>	0,1	0,02	0,18	0,21	0,09	0,1	0,11	0,16	0,1	0,2	-0,21	
t_vm		1	-0,14	0,33	<u>-0,01</u>	0,34	-0,14	<u>-0</u>	-0,28	0,23	0,46	<u>-0,09</u>	<u>-0,01</u>	<u>-0,07</u>	-0,13	-0,16	<u>-0,08</u>	-0,19	<u>-0,06</u>	-0,12	<u>-0,08</u>	<u>-0,05</u>	-0,21	0,01	0,36	0,21	0,32	0,24	0,3	0,16	0,21	-0,31	
a_s_ta			1	-0,47	-0,13	<u>-0,05</u>	-0,15	-0,21	0,01	<u>-0,07</u>	<u>-0,06</u>	<u>-0,09</u>	0,28	0,22	0,25	0,48	0,13	0,43	0,13	0,21	0,14	0,19	0,52	0,44	0,01	0,06	-0,2	0,07	0,06	0,13	0,08	0,05	
a_cf_s				1	0,19	0,58	<u>-0,02</u>	0,08	-0,26	0,19	0,37	<u>-0,07</u>	-0,26	-0,11	-0,16	-0,4	<u>-0,01</u>	-0,26	<u>-0,02</u>	-0,14	-0,11	-0,23	-0,4	-0,24	0,38	0,35	0,58	0,31	0,38	0,18	0,15	-0,21	
a_vvtas					1	0,13	0,12	0,1	0,09	<u>0</u>	0,05	0,14	-0,11	<u>-0,06</u>	-0,1	<u>-0,03</u>	<u>-0,08</u>	-0,12	-0,11	<u>-0,08</u>	-0,1	0,09	-0,11	0,01	0,14	0,2	0,2	0,18	0,18	0,09	<u>0</u>	<u>-0,07</u>	
f_cf_td						1	-0,26	-0,14	-0,49	0,24	0,55	-0,29	<u>-0,06</u>	0,07	0,03	-0,15	0,15	0,02	0,16	0,04	<u>-0</u>	-0,12	<u>-0,07</u>	0,06	0,59	0,48	0,53	0,51	0,56	0,3	0,37	-0,22	
f_ltd_ce							1	0,54	0,5	-0,21	-0,31	0,79	<u>-0,08</u>	-0,21	-0,18	<u>-0,09</u>	-0,18	-0,22	-0,19	-0,22	-0,13	<u>-0,08</u>	-0,24	-0,19	-0,24	0,01	<u>-0,08</u>	-0,14	-0,11	-0,17	-0,29	<u>0</u>	
f_fa_ce								1	0,3	<u>-0,04</u>	-0,17	0,58	<u>-0,08</u>	-0,27	-0,27	-0,18	-0,17	-0,32	-0,2	-0,25	-0,15	<u>-0,04</u>	-0,35	-0,24	<u>-0,06</u>	0,1	0,11	-0,15	0,02	<u>-0,09</u>	<u>-0,06</u>	-0,21	
f_td_ta									1	-0,37	-0,48	0,66	<u>-0,1</u>	-0,28	-0,2	0,18	-0,27	<u>-0,06</u>	-0,29	-0,25	<u>-0,09</u>	0,01	<u>-0,07</u>	-0,12	-0,34	-0,11	-0,23	-0,24	-0,23	0,04	-0,41	0,15	
f_dp_e										1	0,21	-0,22	0,02	0,05	<u>0</u>	<u>-0,09</u>	0,08	<u>-0,03</u>	0,1	0,04	0,04	<u>-0,05</u>	<u>-0,04</u>	0,06	0,28	0,15	0,25	0,18	0,2	0,1	0,32	-0,33	
f_mve_t											1	-0,3	0,03	0,09	0,03	-0,14	0,12	0,02	0,11	0,05	0,08	-0,11	<u>-0,03</u>	0,09	0,49	0,33	0,42	0,42	0,44	0,21	0,34	-0,28	
f_td_ce												1	<u>-0,06</u>	-0,21	-0,19	0,02	-0,22	-0,18	-0,23	-0,23	-0,15	<u>-0,01</u>	-0,19	<u>-0,09</u>	-0,18	0,05	<u>-0,05</u>	<u>-0,1</u>	<u>-0,05</u>	-0,1	-0,21	<u>-0,04</u>	
l_s_wc													1	0,19	0,16	0,16	0,09	0,22	0,11	0,1	0,11	0,23	0,3	0,19	<u>-0,04</u>	-0,13	-0,22	<u>-0,04</u>	<u>-0,07</u>	-0,11	0,07	<u>-0</u>	
l_wc_ltd														1	0,86	<u>-0,02</u>	0,63	0,44	0,61	0,79	0,39	0,22	0,54	0,05	<u>-0,02</u>	-0,11	-0,13	0,01	<u>-0,07</u>	-0,18	0,1	0,2	
l_wc_ta															1	<u>-0,01</u>	0,63	0,47	0,62	0,84	0,41	0,23	0,58	0,02	<u>-0,08</u>	-0,14	-0,19	<u>-0,02</u>	-0,11	-0,19	0,05	0,24	
l_cl_ta																1	-0,11	0,39	-0,12	<u>-0,06</u>	0,02	0,11	0,41	0,7	<u>-0,01</u>	0,02	-0,14	0,09	0,03	0,18	<u>-0,05</u>	0,05	
l_quick																	1	0,49	0,9	0,66	0,54	<u>-0,06</u>	0,39	<u>-0,05</u>	0,05	<u>-0,04</u>	<u>-0,04</u>	0,03	<u>-0,02</u>	-0,13	0,09	0,18	
l_cas_ta																		1	0,49	0,43	0,46	<u>-0,05</u>	0,71	0,37	<u>-0,02</u>	<u>-0,04</u>	-0,16	0,07	<u>-0,03</u>	0,04	<u>0</u>	0,21	
l_cas_cl																			1	0,66	0,54	<u>-0,09</u>	0,39	<u>-0,06</u>	0,03	<u>-0,06</u>	<u>-0,06</u>	0,02	<u>-0,04</u>	-0,16	0,09	0,21	
l_ca_cl																				1	0,45	0,25	0,53	<u>-0,02</u>	<u>-0,06</u>	-0,13	-0,18	<u>-0,02</u>	-0,11	-0,19	0,06	0,23	
l_c_cl																					1	<u>-0,09</u>	0,38	0,01	<u>-0,04</u>	<u>-0,09</u>	<u>-0,07</u>	<u>-0,02</u>	<u>-0,08</u>	-0,11	<u>-0,04</u>	0,19	
l_i_tca																						1	0,24	0,07	<u>-0,07</u>	-0,11	-0,19	<u>-0,05</u>	<u>-0,09</u>	-0,11	0,04	<u>-0,02</u>	
l_ca_ta																							1	0,38	<u>-0,1</u>	-0,15	-0,29	<u>-0,01</u>	-0,12	<u>-0,06</u>	0,01	0,22	
l_cl_tl																								1	0,14	0,08	<u>-0,02</u>	0,19	0,15	0,16	0,12	<u>-0,03</u>	
g_ebit_i																									1	0,62	0,66	0,68	0,76	0,49	0,51	-0,34	
g_nia_ta																										1	0,64	0,7	0,81	0,61	0,34	-0,31	
g_ebit_s																											1	0,61	0,72	0,51	0,34	-0,31	
g_ronfa																												1	0,8	0,54	0,41	-0,23	
g_ebit_a																													1	0,66	0,42	-0,34	
g_roe																														1	0,18	-0,21	
g_re_ta																															1	-0,38	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 29. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías del sector Resources.

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_tl	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,62	0,4	-0,2	0,18	0,06	-0,1	-0,1	0	0,25	0,07	0,13	0,05	-0	-0	0,29	-0,1	0,12	-0,1	-0	-0,1	0,32	0,15	0,29	0,23	0,11	-0	0,18	0,18	0,05	0,36	-0,3	
t_vm		1	0,1	0,08	0,07	0,23	-0,3	-0,1	-0,2	0,29	0,33	-0,1	-0	0,01	-0	0,08	-0	0,05	-0	-0	0,03	0,17	0,04	0,18	0,35	0,22	0,2	0,27	0,28	0,13	0,37	-0,4	
a_s_ta			1	-0,5	0,18	-0,1	-0	-0,1	0,14	0,07	-0,1	0,19	0,13	0,09	0,08	0,53	-0,1	0,31	-0,1	0,06	-0,1	0,37	0,41	0,46	0,04	0,12	-0,2	0,09	0,06	-0	0,18	-0,1	
a_cf_s				1	-0,1	0,58	-0	0,14	-0,3	0,01	0,24	-0,1	-0,1	-0,1	-0,4	0,06	-0,3	0,08	-0,1	0,03	-0,3	-0,4	-0,3	0,25	0,25	0,5	0,18	0,29	0,2	0,06	-0,1		
a_vvtas					1	-0	0,07	0,11	0,06	0,03	-0	0,19	0	0,01	-0	0,06	-0,1	-0,1	-0,1	0,01	0,04	0,19	-0	0,04	0,08	0,09	0,05	0,05	0,09	0,03	0,01	-0,1	
f_cf_td						1	-0,2	-0,1	-0,5	0,11	0,46	-0,2	-0,1	0,05	0,03	-0,1	0,11	-0	0,13	0,04	0,07	-0,1	-0,1	0,08	0,49	0,43	0,51	0,41	0,5	0,3	0,26	-0,2	
f_ltd_ce							1	0,62	0,4	-0,1	-0,4	0,65	-0	-0,2	-0,1	-0,1	-0,2	-0,3	-0,1	-0,2	-0,1	-0,1	-0,3	-0,3	-0,3	-0,1	-0,2	-0,2	-0,1	-0,2	0,01		
f_fa_ce								1	0,4	-0	-0,3	0,66	-0,1	-0,3	-0,3	-0,1	-0,3	-0,4	-0,3	-0,3	-0,2	-0,1	-0,4	-0,3	-0,1	0	-0	-0,2	-0,1	-0	-0,1	-0,1	
f_td_ta									1	-0,1	-0,5	0,66	0,02	-0,3	-0,2	0,25	-0,3	-0	-0,3	-0,3	-0,3	0,03	0,01	-0,1	-0,4	-0,2	-0,3	-0,3	-0,3	-0,1	-0,2	-0	
f_dp_e										1	0,15	-0	-0,1	-0	-0	-0	-0	-0	-0	-0	-0	0,16	-0	0,01	0,32	0,26	0,17	0,28	0,27	0,18	0,16	-0,3	
f_mve_tl											1	-0,4	0,03	0,25	0,19	-0,1	0,25	0,06	0,21	0,21	0,25	0,05	0,04	0,13	0,43	0,25	0,34	0,36	0,37	0,15	0,28	-0,1	
f_td_ce												1	0,03	-0,2	-0,2	0,13	-0,3	-0,1	-0,3	-0,2	-0,2	0,08	-0,1	-0,1	-0,2	-0,1	-0,2	-0,2	-0,2	-0,1	-0,1	-0	
l_s_wc													1	0,22	0,15	0,06	0,06	0,1	0,09	0,08	0,12	0,16	0,17	0,06	-0,1	-0	-0,1	-0,1	-0,1	-0,2	0,03	0,18	
l_wc_ltd														1	0,87	-0,1	0,56	0,4	0,6	0,77	0,4	0,13	0,4	0,04	0,03	0,01	-0	0,08	-0	-0,1	0,1	0,28	
l_wc_ta															1	-0,1	0,58	0,39	0,62	0,83	0,4	0,15	0,42	0	0,03	-0	-0	0,1	-0	-0,1	0,08	0,31	
l_cl_ta																1	-0,2	0,38	-0,3	-0,2	-0,1	0,27	0,47	0,69	-0,1	-0	-0,3	0,01	-0,1	0,08	0,06	-0	
l_quick																	1	0,34	0,83	0,65	0,48	-0,2	0,21	-0,1	0,11	-0	0,08	0,12	0,05	-0,1	0,11	0,21	
l_cas_ta																		1	0,35	0,36	0,21	0,02	0,76	0,45	0,01	-0	-0,2	0,05	-0,1	0,04	0,14	0,14	
l_cas_cl																			1	0,72	0,45	-0,2	0,22	-0,1	0,1	-0	0,07	0,1	0,04	-0,1	0,11	0,25	
l_ca_cl																				1	0,43	0,1	0,36	-0	0,07	-0	-0	0,1	0,01	-0,1	0,11	0,28	
l_c_cl																					1	-0,1	0,16	-0	0,05	-0	0,05	0,05	0,02	-0,1	-0	0,23	
l_i_tca																						1	0,26	0,25	0,02	0,02	-0,1	0,08	0,01	-0,1	0,07	-0	
l_ca_ta																							1	0,51	-0	-0,1	-0,3	0,04	-0,1	-0	0,09	0,18	
l_cl_tl																								1	0,11	0,06	-0,1	0,14	0,08	0,12	0,16	-0	
g_ebit_i																									1	0,62	0,66	0,77	0,81	0,56	0,39	-0,3	
g_nia_ta																										1	0,59	0,66	0,74	0,61	0,25	-0,3	
g_ebit_s																											1	0,61	0,73	0,57	0,24	-0,2	
g_ronfa																												1	0,84	0,62	0,32	-0,3	
g_ebit_a																													1	0,66	0,34	-0,3	
g_roe																														1	0,15	-0,3	
g_re_ta																															1	-0,3	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 30. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías del sector Basic Industries.

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_tl	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,69	0	0,21	0,13	0,21	-0,1	0,02	-0,1	0,17	0,2	0,03	0,15	-0	-0,2	0,08	-0,1	-0	-0,1	-0,2	-0,1	-0	-0,1	0,13	0,25	0,14	0,22	0,2	0,21	0,14	0,2	-0,3	
t_vm		1	-0,1	0,39	0,11	0,34	-0,1	0,05	-0,2	0,26	0,44	-0	0,12	-0,1	-0,2	-0	-0,1	-0,1	-0,2	-0	-0,1	-0,2	0,07	0,35	0,24	0,34	0,27	0,31	0,17	0,32	-0,5		
a_s_ta			1	-0,2	0,11	0,08	-0,1	-0,2	0,03	-0,1	0,04	0,01	0,05	0,26	0,21	0,35	-0	0,28	-0	0,08	-0,1	0,14	0,46	0,33	0,13	0,16	0,07	0,17	0,16	0,21	0,04	0,16	
a_cf_s				1	0,07	0,65	-0,1	0,05	-0,3	0,32	0,4	-0,1	0,08	-0	-0,1	-0,2	0,02	-0,1	0,05	-0	0,01	-0,1	-0,2	-0,1	0,41	0,38	0,49	0,35	0,41	0,21	0,4	-0,4	
a_vvtas					1	0,2	0,03	-0,1	-0,1	0,08	0,16	0	-0,1	0,14	0,13	-0	0,01	-0,1	-0,1	0,15	0,06	0,18	0,11	0,05	0,3	0,3	0,29	0,33	0,32	0,22	0,1	-0,1	
f_cf_td						1	-0,2	-0,1	-0,4	0,31	0,53	-0,3	0,06	0,19	0,09	-0,1	0,08	0,02	0,07	0,1	0,04	-0	0,02	0,1	0,6	0,56	0,64	0,54	0,62	0,37	0,5	-0,4	
f_ltd_ce							1	0,49	0,44	-0,1	-0,2	0,7	0,09	-0,2	-0	-0,1	0,01	-0,1	0,01	0,01	0,03	0,01	-0,2	-0,3	-0,2	-0,1	-0,1	-0,1	-0,1	-0,2	-0,2	0,06	
f_fa_ce								1	0,24	-0	-0,1	0,5	0,21	-0,3	-0,3	-0,2	-0,1	-0,3	-0,1	-0,2	-0,1	0,06	-0,4	-0,3	-0,3	-0,2	-0,3	-0,4	-0,3	-0,4	-0,1	-0	
f_td_ta									1	-0,2	-0,5	0,68	0,04	-0,3	-0,2	0,16	-0,2	0,05	-0,1	-0,2	-0,1	-0,1	-0	-0,1	-0,3	-0,2	-0,3	-0,3	-0,3	-0,1	-0,4	0,23	
f_dp_e										1	0,25	-0,1	0,09	0,03	-0,1	0,04	0,03	0,05	0,03	-0,1	-0	-0,1	-0	0,11	0,32	0,21	0,28	0,21	0,24	0,2	0,19	-0,3	
f_mve_tl											1	-0,3	0,05	0,18	0,06	-0,1	0,04	0,01	0,03	0,06	0,05	-0	0,01	0,11	0,46	0,42	0,47	0,41	0,47	0,26	0,46	-0,5	
f_td_ce												1	0,12	-0,2	-0,1	0,06	-0,1	-0	-0,1	-0,2	-0	-0	-0,1	-0,1	-0,2	-0,1	-0,2	-0,1	-0,2	-0,2	-0,2	0,05	
l_s_wc													1	-0,2	-0,4	-0,1	-0,2	-0,1	-0,2	-0,4	-0,2	-0	-0,3	-0,1	0,05	-0	0,01	0	0,01	-0,1	0,06	-0,1	
l_wc_ltd														1	0,73	0,05	0,39	0,31	0,35	0,58	0,22	0,12	0,53	0,19	0,24	0,22	0,23	0,28	0,26	0,13	0,19	0,02	
l_wc_ta															1	-0,1	0,5	0,26	0,45	0,77	0,3	0,16	0,51	-0	0,09	0,15	0,14	0,17	0,16	0,09	0,1	0,11	
l_cl_ta																1	-0,2	0,4	-0,2	-0,3	-0,1	-0,1	0,42	0,72	0,11	0,06	0,05	0,11	0,08	0,2	-0,1	0,09	
l_quick																	1	0,36	0,86	0,53	0,46	-0,3	0,19	-0,1	0,09	0,07	0,07	0,07	0,06	-0	0,07	-0	
l_cas_ta																		1	0,37	0,08	0,24	-0,4	0,56	0,36	0,12	0,08	0,05	0,11	0,06	0,14	0,01	0,03	
l_cas_cl																			1	0,49	0,39	-0,3	0,13	-0,2	0,05	0,05	0,03	0,04	0,02	-0,1	0,08	-0	
l_ca_cl																				1	0,32	0,2	0,29	-0,2	0,04	0,12	0,11	0,12	0,12	0,03	0,11	0,1	
l_c_cl																					1	-0,2	0,19	-0,1	0,09	0,11	0,07	0,07	0,09	0,08	-0	0	
l_i_tca																						1	0,04	-0,1	-0,1	-0	-0	-0,1	-0	-0	-0	-0	0,11
l_ca_ta																							1	0,42	0,14	0,16	0,13	0,22	0,18	0,25	0,02	0,17	
l_cl_tl																								1	0,24	0,16	0,18	0,22	0,21	0,22	0,09	-0	
g_ebit_i																									1	0,73	0,79	0,8	0,83	0,61	0,42	-0,4	
g_nia_ta																										1	0,74	0,75	0,82	0,63	0,38	-0,3	
g_ebit_s																											1	0,77	0,85	0,61	0,44	-0,4	
g_ronfa																												1	0,86	0,66	0,38	-0,3	
g_ebit_a																													1	0,69	0,44	-0,3	
g_roe																														1	0,24	-0,2	
g_re_ta																															1	-0,4	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 31. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías se sector General Industrials.

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_tl	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,71	-0,1	0,09	0,07	0,06	-0,1	0,03	-0,1	0,22	0,11	0,08	0,07	0,05	-0,1	0,2	-0,1	0,11	-0,1	-0,2	0,13	-0,2	0,05	0,36	0,2	-0	0,16	0,15	0,12	0,1	0,16	-0,3	
t_vm		1	-0,2	0,26	0,04	0,2	-0,2	0	-0,2	0,24	0,35	-0	0,04	0,08	-0,1	0,04	0	0,02	0,01	-0,1	0,15	-0,2	-0,1	0,26	0,29	0,11	0,28	0,25	0,22	0,11	0,27	-0,4	
a_s_ta			1	-0,2	0,02	0,11	-0,1	-0,1	0,03	-0,1	-0	-0,1	0,16	0,07	0,09	0,19	-0	0,12	-0	0,01	-0,2	0,14	0,27	0,16	0	0,09	-0,1	-0	0,02	-0	0,02	0,02	
a_cf_s				1	0,13	0,59	-0,1	0,07	-0,2	0,27	0,31	-0,1	-0	0,02	-0	-0,2	0,04	-0,3	-0	0,03	0,02	0,05	-0,3	-0,1	0,46	0,45	0,55	0,45	0,49	0,29	0,27	-0,3	
a_vvtas					1	0,08	0,05	0,01	0,09	0,09	-0	0,06	0,05	-0,1	-0,1	0,06	-0,1	-0,1	-0,1	-0,1	-0,1	0,02	-0	0	0,1	0,2	0,15	0,14	0,15	0,12	-0	-0,1	
f_cf_td						1	-0,2	-0	-0,4	0,25	0,48	-0,3	-0	0,22	0,13	-0,2	0,13	-0,1	0,1	0,17	0,01	0,09	-0,1	0,05	0,49	0,46	0,44	0,4	0,49	0,21	0,37	-0,3	
f_ltd_ce							1	0,5	0,44	-0	-0,3	0,72	0,14	-0,3	-0,1	0,03	-0,1	-0,1	-0,1	-0,1	-0,1	-0	-0,1	-0,2	-0,1	-0	-0	-0,1	-0,1	-0	-0,1	0,16	
f_fa_ce								1	0,21	0,19	-0,1	0,53	0,17	-0,2	-0,2	0,02	-0,2	-0,2	-0,2	-0,2	-0,1	0,1	-0,1	-0,1	0,03	0,08	0,08	-0	0,08	0,08	-0	-0,1	
f_td_ta									1	-0,1	-0,5	0,66	0,19	-0,5	-0,4	0,33	-0,3	-0	-0,3	-0,4	-0,2	-0	-0,1	-0,2	-0,2	-0,1	-0,1	-0,1	-0,2	0,1	-0,3	0,17	
f_dp_e										1	0,16	0,05	0,06	0,06	-0	-0,1	-0	-0,1	-0	-0	0,01	0,07	-0,1	-0	0,36	0,25	0,34	0,27	0,32	0,24	0,25	-0,4	
f_mve_tl											1	-0,4	-0,1	0,28	0,17	-0,2	0,17	-0,1	0,18	0,22	0,09	0,02	-0,1	0,09	0,34	0,3	0,31	0,3	0,34	0,07	0,44	-0,3	
f_td_ce												1	0,18	-0,3	-0,2	0,21	-0,2	-0	-0,2	-0,2	-0,1	-0	-0,1	-0	-0	-0	0,04	0,02	-0	0,06	-0,1	0,03	
l_s_wc													1	-0,4	-0,5	0,17	-0,4	-0,2	-0,4	-0,5	-0,3	0,04	-0,2	0,03	0,04	0,09	0,01	0,05	0,04	0,1	0,04	-0	
l_wc_ltd														1	0,74	-0,2	0,53	0,33	0,56	0,67	0,29	0,02	0,43	0,1	0,08	-0	0,01	0,03	0,04	-0,1	0,14	-0,1	
l_wc_ta															1	-0,3	0,62	0,36	0,66	0,82	0,27	0,03	0,47	-0,1	-0	-0,1	-0,1	-0,1	-0	-0,2	0,05	0,05	
l_cl_ta																1	-0,3	0,22	-0,4	-0,5	-0,1	-0,1	0,22	0,5	-0	-0,1	-0,1	-0	-0,1	0,01	-0,1	0,02	
l_quick																	1	0,39	0,83	0,64	0,44	-0,3	0,3	-0,1	-0	-0,1	-0	-0	-0	-0,1	-0	0,07	
l_cas_ta																		1	0,4	0,21	0,3	-0,4	0,65	0,29	-0,1	-0,1	-0,2	-0,2	-0,1	-0,2	-0,1	-0,2	0,12
l_cas_cl																			1	0,68	0,43	-0,3	0,29	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	-0	0,07
l_ca_cl																				1	0,27	0,06	0,29	-0,2	-0	-0	-0	-0	-0	-0	-0,2	0,08	0,04
l_c_cl																					1	-0,3	0,16	-0	0,01	-0,2	-0	-0	-0,1	-0,1	-0,1	-0,1	0,06
l_i_tca																						1	-0,1	-0,1	0,04	0,12	0,03	0,02	0,07	-0,1	0,16	-0,1	
l_ca_ta																							1	0,33	-0,1	-0,1	-0,1	-0,1	-0,1	-0,2	-0,1	0,07	
l_cl_tl																								1	0,13	-0	0,02	0,09	0,06	-0,1	0,06	-0,1	
g_ebit_i																									1	0,61	0,75	0,74	0,78	0,51	0,29	-0,5	
g_nia_ta																										1	0,68	0,65	0,77	0,49	0,3	-0,4	
g_ebit_s																											1	0,8	0,85	0,58	0,29	-0,5	
g_ronfa																												1	0,8	0,53	0,3	-0,4	
g_ebit_a																													1	0,59	0,34	-0,5	
g_roe																														1	0,1	-0,2	
g_re_ta																															1	-0,4	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 32. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías del sector Cyclical Consumer Goods.

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_tl	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,66	0,01	0,02	0,13	0,08	0,01	0,23	0,04	0,31	0,1	0,21	0,2	-0,1	-0,3	0,39	-0,1	0,14	-0,2	-0,3	-0,1	-0,3	-0,1	0,36	0,25	-0	0,09	0,05	0,09	0,13	0,03	-0,3	
t_vm		1	-0,1	0,23	0,13	0,27	-0	0,21	-0,2	0,42	0,35	0,11	0,11	-0	-0,2	0,22	0,02	0,24	0	-0,2	0,08	-0,3	-0,1	0,36	0,45	0,12	0,33	0,2	0,28	0,21	0,22	-0,5	
a_s_ta			1	-0,2	0,13	0,13	-0,2	-0,2	-0,1	-0,2	0,07	-0,2	0,12	0,22	0,19	0,15	-0	-0	-0	0,12	-0,1	0,24	0,32	0,19	0,12	0,27	0,02	0,26	0,23	0,16	0,13	0,01	
a_cf_s				1	0,07	0,47	-0	0,08	-0,2	0,27	0,33	-0,1	-0	0,08	0,07	-0,2	0,19	0,08	0,22	0,12	0,18	-0,2	-0,1	-0,1	0,35	0,3	0,53	0,25	0,36	0,19	0,23	-0,3	
a_vvtas					1	0,22	-0	0,01	-0,1	0,07	0,15	0,02	0,09	-0	-0,1	0,13	-0,1	-0,1	-0,1	-0,1	-0,1	0,01	0,01	0,16	0,28	0,29	0,24	0,29	0,28	0,25	0,09	-0,1	
f_cf_td						1	-0,2	-0	-0,5	0,21	0,61	-0,3	0,04	0,26	0,16	-0,2	0,16	0,02	0,18	0,17	0,15	-0	0,03	0,16	0,52	0,5	0,54	0,43	0,58	0,29	0,43	-0,4	
f_ltd_ce							1	0,54	0,39	0,05	-0,3	0,71	-0	-0,4	-0,1	-0	-0,1	-0,1	-0,1	-0,1	-0,2	-0	-0,1	-0,2	-0,2	-0,1	-0,1	-0,2	-0	-0,1	0,07		
f_fa_ce								1	0,27	0,23	-0,1	0,61	0,13	-0,3	-0,3	0,07	-0,2	-0,1	-0,2	-0,3	-0,2	-0,2	-0,3	-0,1	-0	-0,2	-0,1	-0,3	-0,1	-0	-0	-0,1	
f_td_ta									1	-0	-0,5	0,64	0,05	-0,4	-0,3	0,3	-0,3	-0,1	-0,3	-0,3	-0,2	0,01	-0,1	-0,2	-0,4	-0,3	-0,4	-0,4	-0,4	-0,1	-0,5	0,25	
f_dp_e										1	0,16	0,14	0,11	-0,1	-0,2	0,13	-0,1	0,1	-0,1	-0,2	0,02	-0,2	-0,1	0,19	0,26	0,04	0,19	0,07	0,13	0,16	0,2	-0,3	
f_mve_tl											1	-0,3	0,02	0,32	0,23	-0,2	0,23	0,14	0,24	0,22	0,24	-0	0,12	0,21	0,47	0,35	0,47	0,4	0,47	0,16	0,41	-0,4	
f_td_ce												1	0,1	-0,4	-0,3	0,23	-0,2	-0,1	-0,3	-0,3	-0,2	-0,1	-0,2	-0	-0,2	-0,2	-0,2	-0,2	-0,2	-0	-0,2	0	
l_s_wc													1	-0,1	-0,4	0,15	-0,3	-0,2	-0,3	-0,4	-0,3	0,08	-0,2	0,09	0,05	-0	-0	0,01	0,02	0,01	0,04	-0,1	
l_wc_ltd														1	0,67	-0,3	0,39	0,21	0,39	0,59	0,35	0,11	0,46	0,06	0,19	0,17	0,15	0,24	0,2	-0	0,27	-0,2	
l_wc_ta															1	-0,4	0,52	0,25	0,55	0,84	0,39	0,17	0,54	-0,2	0,09	0,21	0,15	0,22	0,18	-0	0,23	-0,1	
l_cl_ta																1	-0,4	0,08	-0,5	-0,5	-0,3	-0,1	0,08	0,49	0,04	-0,1	-0,1	-0	-0	0,2	-0,2	-0	
l_quick																	1	0,45	0,89	0,58	0,56	-0,2	0,25	-0,2	0,07	0,08	0,17	0,1	0,1	-0,1	0,25	-0,2	
l_cas_ta																		1	0,46	0,18	0,39	-0,5	0,4	0,14	0,11	0,02	0,11	0,08	0,07	0,09	0,13	-0,2	
l_cas_cl																			1	0,62	0,56	-0,2	0,25	-0,2	0,08	0,12	0,2	0,12	0,13	-0,1	0,27	-0,2	
l_ca_cl																				1	0,4	0,17	0,38	-0,3	0,06	0,21	0,17	0,2	0,17	-0,1	0,25	-0,1	
l_c_cl																					1	-0,2	0,23	-0,1	0,07	0,05	0,16	0,09	0,08	-0,1	0,13	-0,2	
l_i_tca																						1	0,15	-0,1	-0,1	0,13	-0	0,08	0,04	-0	-0	0,12	
l_ca_ta																							1	0,16	0,13	0,19	0,1	0,27	0,18	0,13	0,12	-0,1	
l_cl_tl																								1	0,32	0,09	0,13	0,24	0,21	0,19	0,14	-0,2	
g_ebit_i																									1	0,54	0,71	0,6	0,74	0,49	0,37	-0,4	
g_nia_ta																										1	0,64	0,65	0,77	0,47	0,29	-0,2	
g_ebit_s																											1	0,64	0,78	0,49	0,33	-0,3	
g_ronfa																												1	0,75	0,45	0,32	-0,2	
g_ebit_a																													1	0,56	0,35	-0,3	
g_roe																														1	0,12	-0,1	
g_re_ta																															1	-0,4	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 33. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías del sector Non-Cyclical Consumer Goods.

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_tl	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,65	0,17	0,09	-0	0,14	-0,1	0,21	-0	0,41	0,18	0,13	0,12	-0,1	-0,3	0,33	-0,3	-0,1	-0,3	-0,4	-0,2	0,13	-0,1	0,33	0,34	0,2	0,2	0,17	0,26	0,17	0,34	-0,4	
t_vm		1	-0,1	0,29	-0	0,27	-0,2	0,1	-0,1	0,45	0,47	-0	0,04	-0	-0,2	0,22	-0,2	-0	-0,2	-0,2	0,03	0,03	-0,1	0,28	0,45	0,27	0,38	0,23	0,37	0,22	0,4	-0,4	
a_s_ta			1	-0,3	-0	0,04	0,08	0,15	0,16	0,01	-0,1	0,15	0,28	-0	-0	0,32	-0,2	0,07	-0,2	-0,1	-0,2	0,16	0,16	0,22	0,06	0,13	-0,2	0,09	0,12	0,11	0,09	-0,1	
a_cf_s				1	0,12	0,56	-0,1	-0	-0,1	0,17	0,38	-0,1	0,03	-0,1	-0,1	0,08	-0,1	0,09	-0	0,13	-0,1	-0,2	-0	0,4	0,39	0,6	0,32	0,4	0,15	0,25	-0,1		
a_vvtas					1	0,16	-0	-0,1	-0,1	-0,2	0,06	-0,1	0,03	0,02	0,03	-0,1	0,12	-0	0,12	0,11	0,02	-0,1	-0,1	-0	0,03	0	0,03	0,09	0,01	-0,1	-0,1	0,11	
f_cf_td						1	-0,2	-0	-0,4	0,11	0,53	-0,2	0,1	0,11	0,05	-0	0,17	0,13	0,18	0,09	0,19	-0,2	-0	0,2	0,54	0,41	0,44	0,34	0,49	0,12	0,34	-0,1	
f_ltd_ce							1	0,49	0,44	0,04	-0,3	0,73	0,08	-0,3	-0,1	-0,1	-0,1	-0,2	-0,1	-0,1	-0,2	0,11	-0,2	-0,3	-0,1	0,07	0,02	0,04	0,02	0,22	-0,1	-0	
f_fa_ce								1	0,26	0,19	-0,1	0,55	0,17	-0,3	-0,3	0,03	-0,2	-0,3	-0,2	-0,3	-0,2	0,11	-0,3	-0,1	0,07	0,15	0,11	-0,1	0,15	0,28	0,11	-0,2	
f_td_ta									1	0,07	-0,4	0,67	0,1	-0,4	-0,3	0,2	-0,3	-0,2	-0,3	-0,4	-0,3	0,15	-0,2	-0,2	-0,2	0,08	-0,1	-0	-0	0,27	-0,2	-0	
f_dp_e										1	0,19	0,16	0,09	-0,1	-0,2	0,33	-0,3	-0,1	-0,3	-0,3	-0,1	0,18	-0	0,24	0,34	0,27	0,31	0,21	0,32	0,24	0,36	-0,4	
f_mve_tl											1	-0,2	-0	0,19	0,11	0,04	0,14	0,23	0,17	0,1	0,3	-0,2	0,11	0,25	0,53	0,33	0,44	0,29	0,45	0,16	0,37	-0,2	
f_td_ce												1	0,12	-0,3	-0,2	0,1	-0,2	-0,2	-0,3	-0,3	-0,3	0,16	-0,2	-0,1	-0,1	0,13	0,05	0,11	0,08	0,31	-0	-0,1	
l_s_wc													1	-0,1	-0,1	0,07	-0,1	-0	-0,1	-0,2	-0,2	0,09	-0	-0	0,14	0,2	0,1	0,11	0,19	0,13	0,11	-0,2	
l_wc_ltd														1	0,73	-0,1	0,45	0,39	0,47	0,61	0,36	-0	0,49	0,11	0,06	-0,1	-0,1	0,02	-0	-0,2	0,07	0,1	
l_wc_ta															1	-0,2	0,54	0,46	0,56	0,76	0,4	-0,1	0,55	-0	-0	-0,1	-0,1	0	-0,1	-0,1	-0	0,21	
l_cl_ta																1	-0,4	0,14	-0,4	-0,4	-0,2	0,16	0,24	0,6	0,15	0,14	0,07	0,16	0,17	0,19	0,17	-0,2	
l_quick																	1	0,44	0,91	0,67	0,55	-0,4	0,23	-0,2	-0	-0,1	-0	-0	-0,1	-0,2	-0,1	0,27	
l_cas_ta																		1	0,45	0,32	0,46	-0,4	0,63	0,25	0,11	0,01	-0	0,11	0,07	-0	0,01	0,14	
l_cas_cl																			1	0,69	0,57	-0,4	0,24	-0,2	-0	-0,1	-0	-0	-0,1	-0,1	-0,1	0,27	
l_ca_cl																				1	0,42	-0,1	0,33	-0,2	-0,1	-0,1	-0,1	-0	-0,1	-0,2	-0,1	0,26	
l_c_cl																					1	-0,4	0,26	-0	0,09	-0	0,06	0,01	0,02	-0,1	-0	0,14	
l_i_tca																						1	0,01	0,09	-0	0,03	0	0,03	0,01	0,05	0,12	-0,2	
l_ca_ta																							1	0,32	0,03	-0,1	-0,1	0,08	-0	-0	0,01	0,09	-0,2
l_cl_tl																								1	0,29	0,1	0,11	0,21	0,19	0,04	0,23	-0,2	
g_ebit_i																									1	0,54	0,65	0,54	0,7	0,35	0,46	-0,3	
g_nia_ta																										1	0,63	0,57	0,8	0,52	0,36	-0,2	
g_ebit_s																											1	0,59	0,72	0,42	0,36	-0,2	
g_ronfa																												1	0,62	0,38	0,25	-0,2	
g_ebit_a																													1	0,53	0,44	-0,3	
g_roe																														1	0,19	-0,2	
g_re_ta																															1	-0,4	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 34. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías del sector Cyclical Services.

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mv_e_t	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,59	0,21	<u>-0,1</u>	0,04	0,17	<u>-0,1</u>	0,02	-0,1	0,24	0,2	0,04	<u>-0,1</u>	<u>-0</u>	<u>-0,1</u>	0,22	-0,2	0,07	-0,2	-0,1	<u>-0,1</u>	0,19	0,13	0,28	0,26	0,12	0,11	0,15	0,18	0,16	0,26	-0,2	
t_vm		1	<u>-0</u>	0,17	0,11	0,23	-0,1	<u>-0,1</u>	-0,2	0,31	0,43	<u>-0,1</u>	<u>-0,1</u>	<u>-0</u>	<u>-0,1</u>	0,06	<u>-0,1</u>	0,03	<u>-0,1</u>	<u>-0,1</u>	<u>-0,1</u>	0,05	0,02	0,16	0,35	0,17	0,31	0,25	0,28	0,17	0,32	-0,3	
a_s_ta			1	-0,4	0,07	0,32	-0,1	<u>-0</u>	<u>-0</u>	0,05	0,2	<u>-0,1</u>	0,12	0,17	0,16	0,52	-0,1	0,3	-0,1	0,09	<u>-0</u>	0,34	0,48	0,5	0,24	0,34	<u>-0</u>	0,2	0,26	0,22	0,14	<u>-0</u>	
a_cf_s				1	0,05	0,24	0,07	0,06	-0,1	0,13	0,14	<u>0</u>	<u>-0,1</u>	-0,1	-0,1	-0,4	0,04	-0,2	0,05	<u>-0,1</u>	<u>-0,1</u>	-0,2	-0,3	-0,3	0,15	0,12	0,41	0,15	0,16	<u>-0</u>	0,12	-0,2	
a_vvtas					1	0,16	<u>-0</u>	<u>-0</u>	<u>-0,1</u>	<u>-0</u>	0,15	<u>-0</u>	0,01	0,05	0,04	<u>-0</u>	<u>-0,1</u>	<u>-0,1</u>	<u>-0,1</u>	0,02	<u>-0</u>	0,04	<u>-0</u>	<u>-0</u>	0,17	0,22	0,11	0,18	0,2	0,13	<u>-0</u>	0,01	
f_cf_td						1	-0,2	<u>-0</u>	-0,4	0,21	0,54	-0,2	0,09	0,18	0,16	0,1	<u>-0</u>	0,09	<u>-0</u>	0,12	<u>-0</u>	0,14	0,19	0,28	0,54	0,53	0,37	0,42	0,56	0,24	0,41	-0,3	
f_ltd_ce							1	0,57	0,34	<u>-0</u>	-0,3	0,77	<u>-0,1</u>	-0,2	-0,2	-0,1	<u>-0,1</u>	-0,2	<u>-0,1</u>	-0,2	<u>-0,1</u>	<u>-0,1</u>	-0,2	-0,2	-0,2	<u>-0,1</u>	<u>-0,1</u>	-0,1	-0,1	-0,2	-0,2	0,04	
f_fa_ce								1	0,15	0,02	-0,2	0,56	<u>-0,1</u>	-0,2	-0,2	<u>-0,1</u>	-0,2	-0,2	-0,2	-0,2	<u>-0,1</u>	0,01	-0,2	<u>-0,1</u>	<u>-0</u>	0,02	0,01	-0,2	<u>-0</u>	<u>-0,1</u>	0,03	<u>-0,1</u>	
f_td_ta									1	-0,2	-0,4	0,56	-0,1	-0,3	-0,2	0,16	-0,1	0,05	-0,1	-0,2	<u>-0</u>	<u>-0,1</u>	<u>-0</u>	-0,1	-0,3	-0,1	-0,2	-0,2	-0,2	0,02	-0,4	0,18	
f_dp_e										1	0,21	<u>-0</u>	0,01	<u>-0</u>	<u>-0</u>	0,05	<u>-0</u>	0,04	<u>-0</u>	<u>-0,1</u>	<u>-0,1</u>	0,02	0,02	0,14	0,35	0,2	0,32	0,3	0,27	0,15	0,3	-0,3	
f_mv_e_t											1	-0,3	0,09	0,17	0,14	0,1	0,03	0,13	0,04	0,13	0,02	0,08	0,18	0,27	0,5	0,4	0,37	0,4	0,49	0,21	0,4	-0,3	
f_td_ce												1	<u>-0,1</u>	-0,2	-0,2	0,05	-0,1	<u>-0,1</u>	-0,1	-0,2	<u>-0,1</u>	<u>-0</u>	<u>-0,1</u>	<u>-0</u>	-0,1	<u>-0,1</u>	<u>-0,1</u>	<u>-0,1</u>	<u>-0,1</u>	<u>-0,1</u>	-0,1	0,04	
l_s_wc													1	0,26	0,19	<u>-0</u>	0,17	0,12	0,17	0,11	0,09	0,05	0,14	0,03	0,04	0,05	<u>-0</u>	0,04	0,03	<u>-0</u>	0,04	<u>-0</u>	
l_wc_ltd														1	0,84	<u>-0</u>	0,43	0,28	0,44	0,71	0,29	0,18	0,41	0,09	0,1	0,09	<u>-0</u>	0,13	0,1	<u>0</u>	0,12	0,04	
l_wc_ta															1	<u>-0</u>	0,47	0,32	0,48	0,79	0,3	0,16	0,45	0,07	0,06	0,08	<u>-0</u>	0,13	0,08	<u>-0</u>	0,09	0,05	
l_cl_ta																1	-0,2	0,45	-0,2	-0,1	-0,1	0,19	0,51	0,69	0,12	0,12	<u>-0,1</u>	0,13	0,12	0,13	0,05	0,01	
l_quick																	1	0,35	0,87	0,58	0,42	-0,3	0,15	-0,1	<u>-0,1</u>	<u>-0,1</u>	<u>-0</u>	0,01	<u>-0,1</u>	-0,1	<u>-0</u>	0,05	
l_cas_ta																		1	0,33	0,28	0,21	<u>-0,1</u>	0,69	0,42	0,05	0,02	<u>-0,1</u>	0,12	0,04	0,02	0,04	0,05	
l_cas_cl																			1	0,61	0,38	-0,3	0,14	-0,2	<u>-0,1</u>	<u>-0,1</u>	<u>-0</u>	0,01	<u>-0,1</u>	-0,1	<u>-0</u>	0,05	
l_ca_cl																				1	0,34	0,11	0,37	0,01	0,04	0,05	<u>-0</u>	0,13	0,06	<u>-0</u>	0,08	0,06	
l_c_cl																					1	-0,1	0,13	<u>-0,1</u>	<u>-0,1</u>	<u>-0</u>	<u>-0,1</u>	<u>-0</u>	<u>-0,1</u>	<u>-0,1</u>	<u>-0</u>	0,11	
l_i_tca																						1	0,23	0,23	0,13	0,16	<u>-0</u>	0,09	0,15	0,14	0,16	<u>-0</u>	
l_ca_ta																							1	0,54	0,14	0,13	<u>-0</u>	0,2	0,15	0,1	0,11	0,03	
l_cl_tl																								1	0,27	0,17	<u>-0</u>	0,21	0,22	0,12	0,22	<u>-0,1</u>	
g_ebit_i																									1	0,63	0,63	0,69	0,79	0,42	0,48	-0,4	
g_nia_ta																										1	0,54	0,62	0,77	0,42	0,33	-0,3	
g_ebit_s																											1	0,62	0,67	0,33	0,36	-0,4	
g_ronfa																												1	0,72	0,37	0,34	-0,3	
g_ebit_a																													1	0,5	0,44	-0,4	
g_roe																														1	0,17	-0,1	
g_re_ta																															1	-0,4	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 35. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías del sector Non-Cyclical Services.

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_tl	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,65	0,14	0,25	-0	0,4	0,09	0,12	-0,2	0,09	0,42	0,11	-0,1	-0	0,01	0,01	-0,1	-0,1	-0,1	-0	-0,1	0,23	0,06	0,1	0,12	0,11	0,19	0,22	0,2	-0,1	0,31	-0,4	
t_vm		1	-0	0,45	-0	0,51	0,06	0,09	-0,4	0,1	0,65	0,06	-0,1	-0	0,04	-0,2	0,06	-0,1	0,08	0,04	-0	0,1	-0,1	-0	0,15	0,16	0,24	0,24	0,25	-0,2	0,38	-0,4	
a_s_ta			1	-0,2	-0,2	0,13	0,16	0,23	0,04	0,23	0,05	0,24	0,02	0,01	0,06	0,3	-0,3	0,09	-0,2	0,05	-0,2	0,48	0,42	0,21	0,31	0,25	0,27	0,3	0,25	0,02	0,15	-0,2	
a_cf_s				1	-0,1	0,58	-0	-0	-0,3	-0	0,4	-0	-0,2	-0,1	-0	-0,3	0,16	-0,2	0,17	-0	0,01	-0,1	-0,3	-0,2	0,17	0,23	0,27	0,21	0,26	-0	0,25	-0,3	
a_vvtas					1	-0,1	-0,1	-0,1	0,08	-0,1	-0,1	-0,1	-0	-0,1	-0,1	-0	-0,1	-0,1	-0,1	0,05	-0	-0,2	0,03	-0,2	-0,2	-0,2	-0,2	-0,2	-0	-0,2	0,13	-0,2	
f_cf_td						1	0,12	0,17	-0,4	0,17	0,58	0,11	-0,2	-0	0,04	-0,2	-0	-0,2	0,01	0	-0,1	0,16	-0,1	0	0,38	0,42	0,46	0,45	0,47	-0,1	0,44	-0,5	
f_ltd_ce							1	0,78	-0	0,08	0,05	0,83	0,02	0,06	0,14	-0,1	0,08	0,04	0,08	0,14	0,06	0,12	0,12	-0,1	0,2	0,23	0,27	0,29	0,25	-0,3	0,09	-0,2	
f_fa_ce								1	-0,1	0,12	0,1	0,79	-0	-0	0,07	-0	0,05	-0	0,04	0,09	0,08	0,13	0,11	-0	0,23	0,23	0,28	0,26	0,26	-0,3	0,1	-0,2	
f_td_ta									1	-0,2	-0,5	0,12	-0	-0,2	-0,2	0,31	-0,2	0,13	-0,2	-0,2	-0,1	-0,1	0,08	-0,1	-0,3	-0,3	-0,3	-0,3	-0,3	0,34	-0,6	0,48	
f_dp_e										1	0,23	0,1	0,01	0,06	0,08	0,02	-0,1	-0	-0,1	0,06	-0,1	0,18	0,09	0,08	0,46	0,36	0,4	0,38	0,36	0,05	0,29	-0,3	
f_mve_tl											1	0,04	-0,1	0,03	0,12	-0,2	0,08	-0,1	0,1	0,11	-0	0,12	-0,1	0,01	0,37	0,35	0,4	0,4	0,45	-0,1	0,49	-0,6	
f_td_ce												1	0,01	0,06	0,13	0,02	0,06	0,06	0,06	0,15	0,06	0,16	0,19	-0	0,22	0,24	0,28	0,31	0,27	-0,3	0,11	-0,2	
l_s_wc													1	0,26	0,22	-0	0,1	0,14	0,11	0,16	0,16	0,01	0,2	-0	-0,1	-0,1	-0,1	-0,1	-0,1	-0	-0	0,08	
l_wc_ltd														1	0,83	-0,3	0,46	0,22	0,49	0,77	0,37	0,07	0,33	-0,3	0,03	0,1	0,06	0,11	0,09	-0,1	0,12	-0,1	
l_wc_ta															1	-0,3	0,52	0,23	0,55	0,83	0,4	0,07	0,35	-0,3	0,09	0,16	0,13	0,16	0,15	-0,2	0,18	-0,1	
l_cl_ta																1	-0,4	0,22	-0,5	-0,3	-0,3	0,12	0,33	0,62	-0	-0,1	-0,1	-0	-0,1	0,24	-0,2	0,11	
l_quick																	1	0,33	0,92	0,61	0,66	-0,3	0,11	-0,4	-0,1	-0	0	-0	-0	-0,2	0,02	0,02	
l_cas_ta																		1	0,32	0,24	0,37	-0,2	0,62	0,11	-0,2	-0,2	-0,1	-0,1	-0,2	0,03	-0,2	0,17	
l_cas_cl																			1	0,65	0,64	-0,3	0,12	-0,4	-0,1	-0	0	-0	-0	-0,2	0,03	0,02	
l_ca_cl																				1	0,49	0,05	0,34	-0,3	0,07	0,14	0,12	0,12	0,13	-0,2	0,16	-0,1	
l_c_cl																					1	-0,3	0,18	-0,3	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	0,07	
l_i_tca																						1	0,16	0,12	0,27	0,27	0,25	0,28	0,27	-0,1	0,31	-0,2	
l_ca_ta																							1	0,2	0,06	0,03	0,06	0,11	0,03	0,01	-0	-0	
l_cl_tl																								1	0,02	-0	-0	0,04	0,01	0,06	0,1	-0,1	
g_ebit_i																									1	0,76	0,78	0,78	0,81	0,17	0,45	-0,4	
g_nia_ta																										1	0,79	0,79	0,84	0,2	0,44	-0,4	
g_ebit_s																											1	0,83	0,86	0,16	0,48	-0,5	
g_ronfa																												1	0,89	0,14	0,51	-0,5	
g_ebit_a																													1	0,18	0,54	-0,5	
g_roe																														1	-0,2	0,09	
g_re_ta																															1	-0,6	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 36. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías del sector Utilities.

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_tl	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,63	0,05	-0,1	0,03	-0,1	0,17	0,04	0,18	-0,1	-0,1	0,2	-0,1	-0,1	-0,1	0,19	-0	0,16	0	-0,1	-0	-0,1	0,11	0,13	-0	-0,2	-0,1	-0,1	-0,1	-0,1	0,07		
t_vm		1	0,01	0,19	0,19	0,15	0,08	0,01	-0	0,08	0,11	0,07	-0,1	-0,2	-0,2	0,06	-0,1	-0	-0,1	-0,2	-0,1	0,03	-0,1	0,07	0,18	-0	0,14	0,13	0,1	0,04	0,2	-0,3	
a_s_ta			1	-0,4	0,04	0,21	-0,1	-0,1	-0,1	0,03	0,22	-0,1	-0,1	0	0,04	0,06	0,07	0,13	0,03	0,1	-0,1	0,19	0,19	0,07	0,15	0,23	-0,1	0,16	0,19	0,15	0,08	-0	
a_cf_s				1	0,04	0,37	0	0,11	-0,1	0,14	0,11	-0,1	0,11	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	0	0,04	-0,3	-0,1	0,22	0,14	0,44	0,14	0,21	0,11	0,29	-0,2		
a_vvtas					1	0,17	-0	-0,1	-0,2	0,13	0,24	-0,2	-0,1	-0,1	-0,1	-0,2	-0	-0,2	-0,1	-0,1	-0,1	0,09	-0,2	-0,1	0,22	0,2	0,22	0,21	0,23	0,08	0,17	-0,3	
f_cf_td						1	-0,3	-0,1	-0,4	0,16	0,52	-0,4	0	-0,1	-0	-0,1	-0	-0,1	-0,1	-0	-0,1	0,21	-0,1	0,02	0,56	0,48	0,42	0,42	0,56	0,31	0,51	-0,3	
f_ltd_ce							1	0,48	0,45	-0	-0,3	0,61	-0,1	0,12	0,04	-0	-0	-0	0,04	0	0,08	-0	-0,1	-0,1	-0,4	-0,2	-0,2	-0,2	-0,3	-0,2	-0,3	0,12	
f_fa_ce								1	0,33	-0,1	-0,2	0,5	-0	-0,1	-0,1	0,06	-0,2	-0,1	-0,1	-0,1	0,05	0,05	-0,1	-0	-0,3	-0,1	-0,1	-0,3	-0,2	-0,2	-0,2	0,08	
f_td_ta									1	-0,3	-0,5	0,75	0,05	-0	-0,1	0,23	-0,1	0,17	0,01	-0	0,1	-0,2	0,12	0,02	-0,4	-0,3	-0,4	-0,3	-0,4	-0	-0,4	0,31	
f_dp_e										1	0,23	-0,2	-0	-0	0	-0,2	0,03	-0,2	-0	0,01	-0,1	0,15	-0,2	-0,1	0,17	0,24	0,26	0,16	0,19	0,08	0,15	-0,2	
f_mve_tl											1	-0,5	-0,1	-0,1	-0	-0,1	0,04	-0,1	-0,1	-0	-0,1	0,22	-0,1	0,02	0,5	0,49	0,36	0,42	0,56	0,25	0,51	-0,3	
f_td_ce												1	-0	-0	-0,1	0,24	-0,1	0,14	-0	-0,1	0,05	-0,1	0,1	0,12	-0,3	-0,2	-0,3	-0,2	-0,3	-0,2	-0,3	0,23	
l_s_wc													1	-0	-0,1	-0,1	0,02	-0,1	-0	-0,1	0,06	0,07	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	0,01	-0,1	0,04	
l_wc_ltd														1	0,89	-0,3	0,56	0,29	0,72	0,79	0,42	-0,1	0,3	-0,3	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	0,24	
l_wc_ta															1	-0,3	0,61	0,34	0,79	0,86	0,4	-0,1	0,35	-0,3	-0,1	-0,1	-0,1	-0,1	-0	-0	-0,1	0,24	
l_cl_ta																1	-0,2	0,35	-0,2	-0,2	-0,2	-0,1	0,35	0,78	-0,1	-0,2	-0,2	-0,1	-0,1	-0	-0,1	0,13	
l_quick																	1	0,35	0,69	0,64	0,49	-0,3	0,31	-0,2	0,03	0,06	-0	0,03	0,05	0,05	-0	0,14	
l_cas_ta																		1	0,5	0,42	0,25	-0,3	0,85	0,29	-0,1	-0,2	-0,2	-0,1	-0,1	-0	-0,1	0,36	
l_cas_cl																			1	0,81	0,46	-0,3	0,45	-0,2	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	-0,1	0,3	
l_ca_cl																				1	0,42	-0,1	0,43	-0,2	-0	-0	-0,1	-0	-0	-0	-0,1	0,27	
l_c_cl																					1	-0,3	0,2	-0,2	-0,1	-0,1	-0,1	-0,1	-0,1	-0	-0	0,3	
l_i_tca																						1	-0,2	-0,1	0,08	0,14	0,1	0,05	0,13	0,02	0,08	-0,2	
l_ca_ta																							1	0,3	-0,1	-0,1	-0,2	-0,1	-0,1	-0	-0,1	0,35	
l_cl_tl																								1	0,05	-0,1	-0,1	0,03	-0	-0,1	0,02	0,03	
g_ebit_i																									1	0,54	0,62	0,74	0,77	0,52	0,47	-0,4	
g_nia_ta																										1	0,55	0,64	0,73	0,54	0,39	-0,3	
g_ebit_s																											1	0,62	0,67	0,47	0,41	-0,3	
g_ronfa																												1	0,79	0,64	0,38	-0,3	
g_ebit_a																													1	0,6	0,47	-0,3	
g_roe																														1	0,21	-0,1	
g_re_ta																															1	-0,3	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal

Tabla A 37. Matriz de Correlaciones Tau-b de Kendall para las variables de compañías se sector Information Technology.

	t_vtas	t_vm	a_s_ta	a_cf_s	a_vvtas	f_cf_td	f_ltd_ce	f_fa_ce	f_td_ta	f_dp_e	f_mve_tl	f_td_ce	l_s_wc	l_wc_ltd	l_wc_ta	l_cl_ta	l_quick	l_cas_ta	l_cas_cl	l_ca_cl	l_c_cl	l_i_tca	l_ca_ta	l_cl_tl	g_ebit_i	g_nia_ta	g_ebit_s	g_ronfa	g_ebit_a	g_roe	g_re_ta	v_vol250	
t_vtas	1	0,63	0,29	0,16	0,09	0,22	-0,1	0,07	0	-0,1	0,08	0,07	0,22	0,09	-0,1	0,35	-0,2	0,05	-0,2	-0,2	-0,3	0,14	0,09	0,37	0,18	0,2	0,27	0,23	0,24	0,15	0,31	-0,4	
t_vm		1	0,02	0,3	0,11	0,32	-0,1	0,06	-0,2	-0,1	0,36	-0	-0	0,17	0,05	0,09	0,01	0,08	0,02	0,01	-0	0	0,06	0,26	0,2	0,24	0,29	0,3	0,29	0,14	0,39	-0,4	
a_s_ta			1	-0,1	0,12	0,09	-0,1	0,04	0,2	0,02	-0,2	0,14	0,39	0,04	-0,2	0,6	-0,4	0,13	-0,4	-0,4	-0,5	0,23	0,23	0,43	0,12	0,12	0,2	0,07	0,1	0,12	0,06	-0,1	
a_cf_s				1	0,33	0,74	-0	0,04	-0,2	0,09	0,35	-0,1	-0,1	0,06	0,02	-0,1	0,09	-0,1	0,11	0,1	0,04	-0,1	-0,1	0,03	0,38	0,46	0,47	0,49	0,46	0,28	0,42	-0,3	
a_vvtas					1	0,37	-0	0,05	-0,1	0,05	0,18	0,02	-0	0,01	0,04	-0	0,05	0,03	0,05	0,05	0	-0	0	0,04	0,31	0,34	0,33	0,34	0,32	0,19	0,19	-0,2	
f_cf_td						1	-0,2	-0	-0,3	0,09	0,41	-0,1	-0	0,17	0,04	-0	0,06	-0	0,07	0,08	-0	-0	-0	0,2	0,46	0,52	0,52	0,53	0,52	0,34	0,44	-0,4	
f_ltd_ce							1	0,51	0,35	0,04	-0,3	0,67	-0	-0,4	-0,1	-0,1	-0	-0,2	-0	-0	-0,1	0,04	-0,2	-0,4	0	-0,1	-0	-0	-0	-0,3	-0,1	0,11	
f_fa_ce								1	0,2	-0	-0,2	0,52	0,1	-0,2	-0,2	-0	-0,2	-0,3	-0,2	-0,2	-0,2	0,2	-0,3	-0,1	0,06	-0	0,02	0,09	0,03	-0,3	0,06	-0	
f_td_ta									1	0,01	-0,6	0,65	0,25	-0,6	-0,4	0,32	-0,5	-0,1	-0,5	-0,5	-0,4	0,04	-0,1	-0,2	-0	-0,1	-0,1	-0,1	-0,1	0,06	-0,3	0,17	
f_dp_e										1	0,07	0,03	0,01	-0	0,05	-0,1	0,1	0,06	0,09	0,06	0,06	-0,1	0,03	-0,1	0,25	0,21	0,15	0,15	0,16	0,17	0,04	0	
f_mve_tl											1	-0,4	-0,2	0,43	0,34	-0,2	0,39	0,17	0,4	0,37	0,35	-0,1	0,12	0,16	0,19	0,23	0,26	0,28	0,28	0,14	0,33	-0,3	
f_td_ce												1	0,14	-0,3	-0,2	0,16	-0,3	-0,2	-0,3	-0,3	-0,3	0,11	-0,1	-0,1	0,1	0,03	0,05	0,06	0,06	-0,3	-0	-0	
l_s_wc													1	-0,1	-0,3	0,33	-0,5	-0,2	-0,5	-0,5	-0,5	0,2	-0,1	0,1	0,02	-0	0,03	-0	-0	0,02	-0	-0	
l_wc_ltd														1	0,59	-0,1	0,35	0,38	0,35	0,41	0,28	0,09	0,41	0,33	0,02	0,04	0,14	0,05	0,11	-0	0,23	-0,2	
l_wc_ta															1	-0,3	0,6	0,46	0,61	0,69	0,54	0,03	0,48	-0	-0	-0	0,06	-0	0,03	-0,1	0,12	-0,1	
l_cl_ta																1	-0,6	0,21	-0,6	-0,6	-0,5	0,1	0,26	0,51	0,02	0,02	0,08	-0	0,01	0,11	-0,1	-0,1	
l_quick																	1	0,22	0,92	0,81	0,78	-0,2	0,14	-0,2	-0	-0	-0	-0	0,02	-0,1	0,08	0,02	
l_cas_ta																		1	0,2	0,19	0,26	-0,2	0,78	0,25	-0	-0	0,07	-0	0,01	0,07	-0	-0	
l_cas_cl																			1	0,85	0,77	-0,2	0,12	-0,2	-0	-0	-0	0,01	0,03	-0,1	0,1	-0	
l_ca_cl																				1	0,69	-0	0,18	-0,2	-0	-0	0,01	0,01	0,03	-0,1	0,12	-0	
l_c_cl																					1	-0,2	0,17	-0,2	-0,1	-0,1	-0,1	-0,1	-0,1	-0	-0	0,08	
l_i_tca																						1	0,06	0,1	-0	-0,1	0,02	-0	-0	-0,1	0,08	-0,1	
l_ca_ta																							1	0,28	0,01	-0	0,07	-0	0	0,02	0,03	-0,1	
l_cl_tl																								1	0,03	0,09	0,19	0,1	0,13	0,05	0,15	-0,2	
g_ebit_i																									1	0,74	0,69	0,74	0,75	0,52	0,42	-0,4	
g_nia_ta																										1	0,75	0,76	0,85	0,64	0,45	-0,4	
g_ebit_s																											1	0,76	0,83	0,55	0,51	-0,4	
g_ronfa																												1	0,83	0,56	0,49	-0,4	
g_ebit_a																													1	0,63	0,53	-0,4	
g_roe																														1	0,26	-0,3	
g_re_ta																															1	-0,5	
v_vol250																																	1

NOTA: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,01 está subrayado, y en los casos restantes el formato es normal.

C.9. Acerca de las anomalías e influencias

Tabla A 38. Distribución de valores missing values y de valores atípicos y extremos

	N	Missing Values		Valores nulos		Nro. de atípicos y extremos (*)			
		n	%	n	%	Bajos		Altos	
				$x_i = 0$		n	%	n	%
t_vtas	1177	0	0,00%	4	0,34%	0	0,00%	139	11,81%
t_vm	1163	14	1,19%	1	0,09%	0	0,00%	134	11,52%
a_s_ta	1177	0	0,00%	4	0,34%	0	0,00%	52	4,42%
a_cf_s	1173	4	0,34%	0	0,00%	41	3,50%	57	4,86%
a_wtas	1173	4	0,34%	0	0,00%	62	5,29%	54	4,60%
a_cf_td	1177	0	0,00%	0	0,00%	34	2,89%	57	4,84%
f_ltd_ce	1175	2	0,17%	14	1,19%	77	6,55%	114	9,70%
f_fa_ce	1172	5	0,42%	3	0,26%	44	3,75%	66	5,63%
f_td_ta	1177	0	0,00%	0	0,00%	8	0,68%	56	4,76%
f_dp_e	1173	4	0,34%	519	44,25%	44	3,75%	79	6,73%
f_mve_tl	1167	10	0,85%	0	0,00%	1	0,09%	96	8,23%
f_td_ce	1175	2	0,17%	0	0,00%	96	8,17%	112	9,53%
l_s_wc	1167	10	0,85%	4	0,34%	116	9,94%	83	7,11%
l_wc_ltd	1153	24	2,04%	0	0,00%	24	2,08%	98	8,50%
l_wc_ta	1167	10	0,85%	0	0,00%	22	1,89%	39	3,34%
l_cl_ta	1167	10	0,85%	0	0,00%	0	0,00%	43	3,68%
l_quick	1161	16	1,36%	0	0,00%	0	0,00%	79	6,80%
l_cas_ta	1154	23	1,95%	0	0,00%	0	0,00%	30	2,60%
l_cas_cl	1154	23	1,95%	0	0,00%	0	0,00%	77	6,67%
l_ca_cl	1167	10	0,85%	0	0,00%	0	0,00%	61	5,23%
l_c_cl	1166	11	0,93%	19	1,63%	0	0,00%	116	9,95%
l_i_tca	1154	23	1,95%	116	10,05%	0	0,00%	6	0,52%
l_ca_ta	1167	10	0,85%	0	0,00%	0	0,00%	1	0,09%
l_cl_tl	1167	10	0,85%	0	0,00%	1	0,09%	19	1,63%
g_ebit_i	1168	9	0,76%	0	0,00%	92	7,88%	88	7,53%
g_nia_ta	1173	4	0,34%	0	0,00%	94	8,01%	29	2,47%
g_ebit_s	1171	6	0,51%	0	0,00%	141	12,04%	30	2,56%
g_ronfa	1169	8	0,68%	0	0,00%	132	11,29%	88	7,53%
g_ebit_a	1175	2	0,17%	0	0,00%	123	10,47%	28	2,38%
g_roe	1174	3	0,25%	0	0,00%	123	10,48%	97	8,26%
g_re_ta	1157	20	1,70%	2	0,17%	103	8,90%	22	1,90%
v_vol250	1152	25	2,12%	2	0,17%	0	0,00%	100	8,68%
		302		688		1378		2150	

Nota (*): número de casos fuera del rango ($C1 - 1,5 \cdot AIC$; $C3 + 1,5 \cdot AIC$), donde AIC es la amplitud intercuartil y C1 y C3 son los cuartiles inferior y superior, respectivamente. Las cifras en negrita son los casos más relevantes.

Tabla A 39. Matriz de correlaciones Tau-b de Kendall de variables Dummy creadas a partir de missing values de las variables originales

	Dm_C_opa	Dm_T_vta	Dm_T_vm	Dm_A_s-t	Dm_A_cf	Dm_A_vvt	Dm_A_cf	Dm_F_ltd	Dm_F_fa	Dm_F_td	Dm_F_dp	Dm_F_mve	Dm_F_td	Dm_L_s-w	Dm_L_wc	Dm_L_wc	Dm_L_d	Dm_L_qui	Dm_L_cas	Dm_L_cas	Dm_L_ca	Dm_L_c-c	Dm_L_it	Dm_L_ca	Dm_L_d	Dm_G_ebi	Dm_G_nia	Dm_G_ebi	Dm_G_ron	Dm_G_ebi	Dm_G_roe	Dm_G_re	Dm_V_vol
Dm_C_opa		0,086						0,248	0,154		0,173	-0,01	0,248	0,105	0,061	0,105	0,105	0,169	0,063	0,063	0,105	0,207	0,063	0,105	0,105	0,111	-0	0,139	0,119	0,248	0,201	0,069	0,06
Dm_T_vta																																	
Dm_T_vm																																	
Dm_A_s-t																																	
Dm_A_cf																																	
Dm_A_vvt																																	
Dm_A_cf																																	
Dm_F_ltd																																	
Dm_F_fa																																	
Dm_F_td																																	
Dm_F_dp																																	
Dm_F_mve																																	
Dm_F_td																																	
Dm_L_s-w																																	
Dm_L_wc																																	
Dm_L_wc																																	
Dm_L_cl																																	
Dm_L_qui																																	
Dm_L_cas																																	
Dm_L_cas																																	
Dm_L_ca																																	
Dm_L_c-c																																	
Dm_L_it																																	
Dm_L_ca																																	
Dm_L_cl																																	
Dm_G_ebi																																	
Dm_G_nia																																	
Dm_G_ebi																																	
Dm_G_ron																																	
Dm_G_ebi																																	
Dm_G_roe																																	
Dm_G_re																																	
Dm_V_vol																																	

Nota: El formato de los valores de las correlaciones es la siguiente: si el valor absoluto es mayor o igual que 0,5 está ennegrecido, si el valor absoluto es menor a 0,03 está subrayado, y en los casos restantes el formato es el común y corriente.

Tabla A 40. Distribución de MV generados por ausencia total de datos

Distribución por rating

R_lpmIn2	1	2	3	5	12	13	15	Total	%
101			1					1	1%
102	10	1	2	1		1		15	16%
103	15	2	5		2			24	26%
104	17	1	2	1	4		1	26	28%
105	2	1	6			1		10	11%
106		1			1			2	2%
107	6	3	4		1			14	15%
Total	50	9	20	2	8	2	1	92	100%

R_lpmIn2	Nº datos totales y su %	
101	50	4%
102	212	18%
103	340	29%
104	299	25%
105	197	17%
106	42	4%
107	37	3%
Total	1177	100%

Distribución por sector industrial

C_indc3	1	2	3	5	12	13	15	Total	%
BASIC	8	1	1	1				11	12%
CYCGD	2	1			1		1	5	5%
CYSER	11	1	8		6	1		27	29%
GENIN	2	1	1			1		5	5%
ITECH	2	4	1					7	8%
NCYCG	5							5	5%
NCYSR	5		2					7	8%
RESOR	10		4	1	1			16	17%
UTILS	5	1	3					9	10%
Total	50	9	20	2	8	2	1	92	100%

C_indc3	Nº datos totales y su %	
BASIC	161	14%
CYCGD	84	7%
CYSER	263	22%
GENIN	115	10%
ITECH	106	9%
NCYCG	153	13%
NCYSR	88	7%
RESOR	112	10%
UTILS	95	8%
Total	1177	100%

Nota: en la tabla de distribución de MV por rating (*R_lpmIn2*), los códigos 101 a 107 corresponden a las clases de rating AAA-AA, A, BBB, BB, B, C y D, respectivamente.

Distribución por sector país

C_pais	1	2	3	5	12	13	15	Total	%
BELGIUM	1							1	1%
CANADA	4		2		1			7	8%
FRANCE	3			1				4	4%
JAPAN			1					1	1%
NETHERLAND	4							4	4%
NORWAY	1							1	1%
SWEDEN	1							1	1%
UNITED KING	1		1					2	2%
UNITED STAT	35	9	16	1	7	2	1	71	77%
Total	50	9	20	2	8	2	1	92	100%

C_pais	Nº datos totales y su %	
BELGIUM	1	0%
CANADA	84	7%
FRANCE	30	3%
JAPAN	26	2%
NETHERLAND	10	1%
NORWAY	4	0%
SWEDEN	9	1%
UNITED KING	60	5%
UNITED STA	922	78%
Total	1177	100%

Distribución por opinión de auditores externos

C_opaud	1	2	3	5	12	13	15	Total	%
N/A	6					1	1	8	9%
Qualified	2		2					4	4%
Unqualified	42	9	18	2	8	1		80	87%
Total	50	9	20	2	8	2	1	92	100%

C_opaud	Nº datos totales y su %	
N/A	8	1%
Qualified	36	3%
Unqualified	1131	96%
Total general	1177	100%

Tabla A 41. Distribución de missing values por categoría de rating

Variable	AAA; AA	A	BBB	BB	B	C	D
t_vtas	0	0	0	0	0	0	0
t_vm	0	0	5	2	2	0	4
a_s_ta	0	0	0	0	0	0	0
a_cf_s	0	1	0	2	0	0	1
a_vvtas	0	1	0	2	0	0	1
f_cf_td	0	0	0	0	0	0	0
f_ltd_ce	0	0	0	2	0	0	0
f_fa_ce	0	1	0	3	0	0	1
f_td_ta	0	0	0	0	0	0	0
f_dp_e	0	0	2	2	0	0	0
f_mve_tl	0	0	1	0	1	1	6
f_td_ce	0	0	0	2	0	0	0
l_s_wc	0	1	2	4	1	1	1
l_wc_ltd	1	2	2	5	5	2	7
l_wc_ta	0	1	2	4	1	1	1
l_cl_ta	0	1	2	4	1	1	1
l_quick	0	1	3	8	2	1	1
l_cas_ta	1	2	6	7	5	1	1
l_cas_cl	1	2	6	7	5	1	1
l_ca_cl	0	1	2	4	1	1	1
l_c_cl	0	1	2	5	1	1	1
l_i_tca	1	2	6	7	5	1	1
l_ca_ta	0	1	2	4	1	1	1
l_cl_tl	0	1	2	4	1	1	1
g_ebit_i	1	3	1	2	2	0	0
g_nia_ta	0	1	1	1	1	0	0
g_ebit_s	0	2	0	3	0	0	1
g_ronfa	0	2	1	3	1	0	1
g_ebit_a	0	1	0	1	0	0	0
g_roe	0	1	0	2	0	0	0
g_re_ta	0	8	6	5	0	0	1
v_vol250	0	0	3	8	3	1	10
Total	5	37	59	103	39	15	44
Distrib. MV	1,7%	12,3%	19,5%	34,1%	12,9%	5,0%	14,6%
Distrib.todos datos	4,2%	18,0%	28,9%	25,4%	16,7%	3,6%	3,1%

Tabla A 42. Distribución de missing values por sector industrial

Variable	RESOR	BASIC	GENIN	CYCGD	NCYCG	CYSER	NCYSR	UTILS	ITECH
t_vtas	0	0	0	0	0	0	0	0	0
t_vm	2	0	1	1	0	2	2	5	0
a_s_ta	0	0	0	0	0	0	0	0	0
a_cf_s	3	0	0	0	0	1	0	0	0
a_vvtas	2	0	0	0	0	2	0	0	0
f_cf_td	0	0	0	0	0	0	0	0	0
f_ltd_ce	0	0	0	1	0	0	0	0	1
f_fa_ce	1	1	0	1	0	1	0	0	1
f_td_ta	0	0	0	0	0	0	0	0	0
f_dp_e	1	0	0	1	1	1	0	0	0
f_mve_tl	1	0	2	1	0	0	2	1	2
f_td_ce	0	0	0	1	0	0	0	0	1
l_s_wc	1	0	1	1	0	7	0	0	0
l_wc_ltd	2	3	1	1	3	7	4	0	3
l_wc_ta	1	0	1	1	0	7	0	0	0
l_cl_ta	1	0	1	1	0	7	0	0	0
l_quick	1	5	1	2	0	7	0	0	0
l_cas_ta	3	1	1	1	0	14	0	2	1
l_cas_cl	3	1	1	1	0	14	0	2	1
l_ca_cl	1	0	1	1	0	7	0	0	0
l_c_cl	1	0	1	2	0	7	0	0	0
l_i_tca	3	1	1	1	0	14	0	2	1
l_ca_ta	1	0	1	1	0	7	0	0	0
l_cl_tl	1	0	1	1	0	7	0	0	0
g_ebit_i	1	2	0	1	0	1	0	0	4
g_nia_ta	0	2	0	0	0	0	0	0	2
g_ebit_s	4	0	0	1	0	1	0	0	0
g_ronfa	3	2	0	1	0	1	1	0	0
g_ebit_a	1	0	0	1	0	0	0	0	0
g_roe	1	0	0	1	0	0	0	0	1
g_re_ta	6	3	2	1	2	2	2	1	1
v_vol250	2	1	3	3	2	5	5	2	2
Total	47	22	22	29	8	122	16	15	21
Distrib. MV	15,6%	7,3%	7,3%	9,6%	2,6%	40,4%	5,3%	5,0%	7,0%
Distrib.todos d	13,7%	7,1%	22,3%	9,8%	9,0%	13,0%	7,5%	9,5%	8,1%

Tabla A 43. Casos con Missing Values y valores nulos por sector industrial

Análisis de "N/A"				
C_indc3	L_s-wc	C_indc3	F_mve-tl	
CYCGD	1	CYCGD	1	
CYSER	7	GENIN	2	
GENIN	1	ITECH	2	
RESOR	1	NCYSR	2	
Total general	10	RESOR	1	
		UTILS	1	
		Total general	9	
C_indc3	L_wc-ltd	C_indc3	T_vm	
CYCGD	1	CYCGD	1	
CYSER	7	CYSER	2	
GENIN	1	GENIN	1	
RESOR	1	NCYSR	2	
Total general	10	RESOR	2	
		UTILS	5	
		Total general	13	
C_indc3	L_wc-ta	C_indc3	G_re-ta	
CYCGD	1	BASIC	3	
CYSER	7	CYCGD	1	
GENIN	1	CYSER	2	
RESOR	1	GENIN	2	
Total general	10	ITECH	1	
		NCYCG	2	
		NCYSR	2	
		RESOR	6	
		UTILS	1	
		Total general	20	
C_indc3	L_cl-ta	C_indc3	V_vol250	
CYCGD	1	BASIC	1	
CYSER	7	CYCGD	3	
GENIN	1	CYSER	5	
RESOR	1	GENIN	3	
Total general	10	ITECH	2	
		NCYCG	2	
		NCYSR	5	
		RESOR	2	
		UTILS	2	
		Total general	25	
C_indc3	L_quick	C_indc3	L_ca-ta	
BASIC	5	CYCGD	1	
CYCGD	2	CYSER	7	
CYSER	7	GENIN	1	
GENIN	1	RESOR	1	
RESOR	1	Total general	10	
Total general	16			
		C_indc3	L_ca-cl	
		CYCGD	1	
		CYSER	7	
		GENIN	1	
		RESOR	1	
		Total general	11	
		C_indc3	L_c-cl	
		CYCGD	2	
		CYSER	7	
		GENIN	1	
		RESOR	1	
		Total general	11	
C_indc3	L_cas-ta	C_indc3	L_ca-cl	
BASIC	1	4%	CYCGD	1
CYCGD	1	4%	CYSER	7
CYSER	14	61%	GENIN	1
GENIN	1	4%	RESOR	1
ITECH	1	4%	Total general	10
RESOR	3	13%		
UTILS	2	9%	C_indc3	L_c-cl
Total general	23	100%	CYCGD	2
			CYSER	7
			GENIN	1
			RESOR	1
			Total general	11
			C_indc3	L_c-cl
			CYCGD	2
			CYSER	7
			GENIN	1
			RESOR	1
			Total general	11
			C_indc3	L_ca-cl
			CYCGD	1
			CYSER	7
			GENIN	1
			RESOR	1
			Total general	10
L_i-tca	N/A			
C_indc3	L_i-tca			
BASIC	1	4%		
CYCGD	1	4%		
CYSER	14	61%		
GENIN	1	4%		
ITECH	1	4%		
RESOR	3	13%		
UTILS	2	9%		
Total general	23	100%		

(Continuación de la página anterior)

Análisis de #iDIV/0!	
C_indc3	A_cf-s
CYSER	1
RESOR	3
Total general	4
C_indc3	L_wc-ltd
BASIC	3
ITECH	3
NCYCG	3
NCYSR	4
RESOR	1
Total general	14
C_indc3	G_ebit-i
BASIC	1
CYSER	1
ITECH	2
Total general	4
C_indc3	G_ebit-s
CYSER	1
RESOR	3
Total general	4

Análisis de $x_i = 0$																								
C_indc3	F_ltd-ce																							
BASIC	3																							
ITECH	3																							
NCYCG	3																							
NCYSR	4																							
RESOR	1																							
Total general	14																							
C_indc3	F_dp-e																							
BASIC	53	10%																						
CYCGD	34	7%																						
CYSER	135	26%																						
GENIN	42	8%																						
ITECH	88	17%																						
NCYCG	71	14%																						
NCYSR	46	9%																						
RESOR	43	8%																						
UTILS	7	1%																						
Total general	519	100%																						
<table border="1"> <thead> <tr> <th colspan="2">Nº datos totales y su %</th> </tr> </thead> <tbody> <tr> <td>161</td> <td>14%</td> </tr> <tr> <td>84</td> <td>7%</td> </tr> <tr> <td>263</td> <td>22%</td> </tr> <tr> <td>115</td> <td>10%</td> </tr> <tr> <td>106</td> <td>9%</td> </tr> <tr> <td>153</td> <td>13%</td> </tr> <tr> <td>88</td> <td>7%</td> </tr> <tr> <td>112</td> <td>10%</td> </tr> <tr> <td>95</td> <td>8%</td> </tr> <tr> <td>1177</td> <td>100%</td> </tr> </tbody> </table>			Nº datos totales y su %		161	14%	84	7%	263	22%	115	10%	106	9%	153	13%	88	7%	112	10%	95	8%	1177	100%
Nº datos totales y su %																								
161	14%																							
84	7%																							
263	22%																							
115	10%																							
106	9%																							
153	13%																							
88	7%																							
112	10%																							
95	8%																							
1177	100%																							
C_indc3	L_c-cl																							
BASIC	5																							
CYCGD	1																							
CYSER	5																							
GENIN	1																							
NCYCG	1																							
NCYSR	2																							
RESOR	4																							
Total general	19																							
C_indc3	L_i-tca																							
BASIC	3	3%																						
CYCGD	1	1%																						
CYSER	45	39%																						
ITECH	21	18%																						
NCYCG	9	8%																						
NCYSR	17	15%																						
RESOR	17	15%																						
UTILS	3	3%																						
Total general	116	100%																						
<table border="1"> <thead> <tr> <th colspan="2">Nº datos totales y su %</th> </tr> </thead> <tbody> <tr> <td>161</td> <td>14%</td> </tr> <tr> <td>84</td> <td>7%</td> </tr> <tr> <td>263</td> <td>22%</td> </tr> <tr> <td>106</td> <td>9%</td> </tr> <tr> <td>153</td> <td>13%</td> </tr> <tr> <td>88</td> <td>7%</td> </tr> <tr> <td>112</td> <td>10%</td> </tr> <tr> <td>95</td> <td>8%</td> </tr> <tr> <td>1177</td> <td>100%</td> </tr> </tbody> </table>			Nº datos totales y su %		161	14%	84	7%	263	22%	106	9%	153	13%	88	7%	112	10%	95	8%	1177	100%		
Nº datos totales y su %																								
161	14%																							
84	7%																							
263	22%																							
106	9%																							
153	13%																							
88	7%																							
112	10%																							
95	8%																							
1177	100%																							

Anexo D. Revisión de supuestos necesarios para las técnicas estadísticas

En esta sección se presentan los resultados de la evaluación de los supuestos asumidos en el AD y logit. Para las 1076 compañías elegidas de la muestra se analizó para la fase 1:

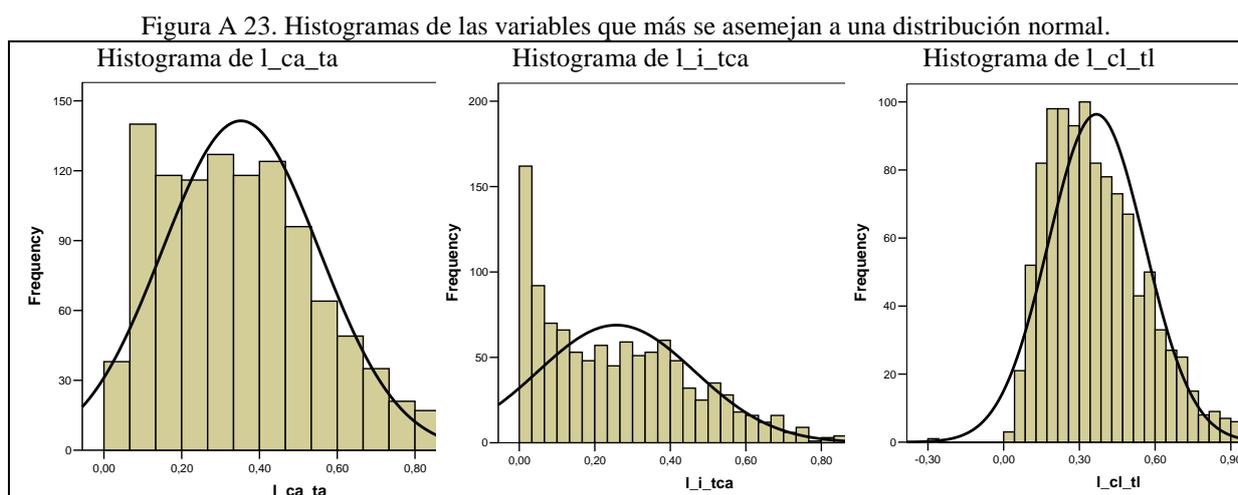
- si las variables independientes tenían una normalidad univariante y multivariante, si las matrices de covarianza y dispersión son iguales para los grupos de datos (separados según la variable dependiente), y si existían multicolinealidad y homocedasticidad,
- si cumplían los niveles de ajuste necesarios para que el uso de la técnica fuese o no adecuada.

Inicialmente se exponen los supuestos para el uso de AD, asumiendo la utilización de M1 en la fase 1; es decir, con dos clases de rating. A posterior se exponen las evidencias de los test de la evaluación de la regresión logística asumiendo el mismo esquema. Luego de esta exposición se muestran las evidencias del análisis de los supuestos con AD y regresión logística, bajo M1, con 7 clases de rating (empleados en la fase 2). En esta sección sólo se adicionan las evidencias relevantes y diferenciadoras de la fase 1.

D.1. Análisis de supuestos de técnicas y modelos usados en la fase 1

Análisis de supuestos para AD aplicado a M1

Desde la forma de los histogramas de las 32 variables de la muestra (ver Figura A 2 hasta la Figura A 7, en la sección 8.3.5 del Anexo) se puede deducir que ninguna de ellas tiene una distribución normal. Sólo las variables l_{ca_ta} , l_{cl_tl} y l_{i_tca} se acercan a dicha condición, pero sus histogramas evidencian que los datos no se ajustan a una distribución normal (ver Figura A 23).



De acuerdo, al test modificado de Kolmogorov-Smirnov (ver la Tabla A 44) sólo la variable l_{ca_ta} se acerca a la forma de una distribución normal con un nivel de significación del 0,1%, lo cual ya es demasiado bajo, debido fundamentalmente a su asimetría. Confirmando estas afirmaciones, los

estadísticos de simetría y curtosis (ver la Tabla A 44) apoyan la ausencia de normalidad en las variables: en la mayoría el estadístico de simetría dista mucho de 1 y el de curtosis dista mucho de 0.

Tabla A 44. Estadísticos que evidencian la falta de normalidad de las 32 variables analizadas.

Statistics			One-Sample Kolmogorov-Smirnov Test			
	Skewness	Kurtosis	Normal Parameters ^{a,b}		Kolmogorov-Smirnov Z	Asymp. Sig. (2-tailed)
			Mean	Std. Deviation		
t_vtas	7,573	81,269	6608900	15844637,1	11,100	,000
a_s_ta	1,864	5,055	,96223	,68453	3,802	,000
f_td_ta	1,539	6,951	,68164	,24313	3,615	,000
f_mv_e_tl	2,858	13,979	,00128	,00160	6,928	,000
l_wc_ta	-,235	6,369	,10835	,19840	3,064	,000
l_cas_ta	1,234	1,695	,25023	,16285	3,066	,000
l_ca_ta	,535	-,328	,35207	,20235	1,976	,001
l_cl_tl	,657	,141	,36742	,19088	2,274	,000
g_ebit_a	-4,695	33,027	-,01275	,17582	7,926	,000
v_vol250	4,359	33,274	57,83358	42,49409	6,050	,000
t_vm	6,900	60,047	6611567	6608900,17	11,949	,000
a_cf_s	-21,009	682,530	,09401	,96223	13,567	,000
a_vvtas	1,623	15,287	,00842	,68164	4,779	,000
f_cf_td	16,718	442,463	,14404	,00128	6,767	,000
f_ltd_ce	18,009	370,456	2,50337	,10835	13,635	,000
f_fa_ce	25,236	712,127	2,79500	,25023	14,100	,000
f_dp_e	-4,250	334,626	,14854	,35207	12,895	,000
f_td_ce	20,445	501,058	4,21604	,36742	13,167	,000
l_s_wc	-11,558	229,532	-5,23408	-,01275	12,227	,000
l_wc_ltd	6,631	450,762	2,41397	57,83358	15,427	,000
l_cl_ta	2,564	15,690	,24372	6611566,56	3,204	,000
l_quick	14,733	268,316	1,20657	,09401	10,834	,000
l_cas_cl	14,587	265,155	1,36056	,00842	10,447	,000
l_ca_cl	13,323	232,531	1,81444	,14404	9,238	,000
l_c_cl	15,253	279,621	,63302	2,50337	13,244	,000
l_i_tca	,683	-,167	,25703	2,79500	3,543	,000
g_ebit_i	-24,458	721,430	,27131	,14854	11,188	,000
g_nia_ta	-3,904	28,451	,03607	4,21604	6,770	,000
g_ebit_s	-26,911	830,364	-,11021	-5,23408	13,794	,000
g_ronfa	8,368	256,838	,00847	2,41397	11,405	,000
g_roe	-24,898	705,029	-,14415	,24372	13,010	,000
g_re_ta	-12,151	188,489	-,02144	1,20657	9,489	,000

a. Test distribution is Normal.

b. Calculated from data.

Debido a que la normalidad univariante no se cumple en casi todas las variables, la normalidad multivariante tampoco lo hará. Para evaluar la igualdad entre las matrices de covarianza entre los grupos de la variable dependiente (por ejemplo, para aquellos con grado de inversión versus aquellos con grado especulativo), usualmente se utiliza el test M de Box de igualdad de matrices de covarianza (Hair et al., 1999; Visauta, 2001). Como en el caso de la muestra, un p-value no significativo implica que no hay evidencias para rechazar la hipótesis nula de que las matrices de covarianza son distintas. Por lo tanto, esto indicaría que las matrices de covarianza podrían ser similares. Sin embargo, siguiendo a Hair et al. (1999), este estadístico es muy sensible a la falta de normalidad de los datos, por lo que, en el caso de la muestra, la confiabilidad no está asegurada.

Tabla A 45. Test M de Box de igualdad de matrices de covarianza de las variables de la muestra

Test agrupando los ratings en 2 clases: inversión versus especulativo			Test agrupando los ratings en 6 clases: AAA-AA, A, BBB, BB, B, C y D		
Box's M		26103,675	Box's M		47059,472
F	Approx.	51,073	F	Approx.	18,478
	df1	496		df1	2244
	df2	3417870		df2	163611,0
	Sig.	,000		Sig.	,000

Siguiendo a Hair et al. (1999), una de las pruebas más usadas para valorar la homocedasticidad es el test de Levene, que evalúa si las varianzas de una única variable métrica son iguales a lo largo de distintos grupos. El test de Levene verifica si las varianzas de dos grupos son iguales para cada variable. Si se supone que para la muestra es necesario un p-value mayor a 0,05 para que los grupos tuviesen igual varianza, entonces, cinco variables serían homocedásticas (con igual varianza): *a_cf_s*, *l_cl_tl*, *l_s_wc*, *l_wc_ltd* y *g_ebit_i* (ver Tabla A 46).

Tabla A 46. Prueba de Levene para evaluar la igual de varianzas por variable.

Independent Samples Test between GRADO

	Levene's Test for Equality of Variances	
	F	Sig.
t_vtas	120,744	,000
a_s_ta	13,020	,000
f_td_ta	77,128	,000
f_mv_e_tl	24,521	,000
l_w_c_ta	30,189	,000
l_cas_ta	23,276	,000
l_ca_ta	18,596	,000
l_cl_tl	2,476	,116
g_ebit_a	137,082	,000
v_vol250	200,089	,000
t_vm	141,532	,000
a_cf_s	2,952	,086
a_vvtas	23,741	,000
f_cf_td	4,817	,028
f_ltd_ce	20,997	,000
f_fa_ce	12,627	,000
f_dp_e	5,649	,018
f_td_ce	16,845	,000
l_s_wc	,375	,540
l_w_c_ltd	3,654	,056
l_cl_ta	9,038	,003
l_quick	23,719	,000
l_cas_cl	23,938	,000
l_ca_cl	23,864	,000
l_c_cl	30,131	,000
l_i_tca	50,888	,000
g_ebit_i	1,731	,189
g_nia_ta	86,957	,000
g_ebit_s	13,504	,000
g_ronfa	15,652	,000
g_roe	14,398	,000
g_re_ta	48,651	,000

Para evaluar la colinealidad entre variables Hair et al. (1999) proponen (1) utilizar un examen de la matriz de correlación de las variables independientes, (2) evaluar el valor de tolerancia y (3) su inverso (el factor de inflación de la varianza, VIF). El primero de estos exámenes se puede realizar con la matriz de correlación de la Tabla A 14, del Anexo C. En esta matriz se puede comprobar la presencia de elevadas correlaciones (mayores al 70% y 80%), sobre todo entre las variables intra-área. Esta es la primera indicación de la existencia de una elevada colinealidad entre algunas variables.

Tabla A 47. Estadísticos de colinealidad que miden la tolerancia y el factor de inflación de la varianza (VIF).

Model	Collinearity Statistics	
	Tolerance	VIF
1		
t_vtas	,477	2,096
a_s_ta	,502	1,994
f_td_ta	,264	3,788
f_mve_tl	,437	2,287
l_wc_ta	,050	19,836
l_cas_ta	,053	18,905
l_cl_tl	,100	10,021
g_ebit_a	,070	14,205
v_vol250	,631	1,584
t_vm	,428	2,337
a_cf_s	,030	33,510
a_vvtas	,866	1,155
f_cf_td	,202	4,953
f_ltd_ce	,033	29,965
f_fa_ce	,061	16,351
f_dp_e	,982	1,019
f_td_ce	,016	61,949
l_s_wc	,978	1,023
l_wc_ltd	,443	2,255
l_cl_ta	,046	21,818
l_quick	,002	497,973
l_cas_cl	,002	531,317
l_ca_cl	,016	63,334
l_c_cl	,016	64,250
l_i_tca	,192	5,212
g_ebit_i	,412	2,429
g_nia_ta	,102	9,770
g_ebit_s	,033	30,240
g_ronfa	,476	2,102
g_roe	,142	7,040
g_re_ta	,516	1,937

Las dos siguientes medidas (la tolerancia y el VIF) indican el grado en que cada variable independiente se explica por las otras variables independientes. La tolerancia “es la cantidad de variabilidad de las variables independientes seleccionadas no explicadas por el resto de las variables independientes” (Hair et al., 1999, página 185). Por lo tanto, un pequeño valor de la tolerancia (y elevados valores del VIF) indican una elevada colinealidad. Es común que si la tolerancia es mayor a 0,10 (lo que corresponde a una correlación múltiple de 0,95), se puede expresar que la variable no está colinealmente relacionada con las restantes variables. En la Tabla A 47 se indica la relación de colinealidad entre las variables (donde cada variable independiente se convierte en una variable criterio o dependiente y se realiza la regresión con el resto de las variables independientes), excepto la

variable *l_ca_ta* cuya tolerancia es cercana a cero y el software SPSS la separa inmediatamente (ver Tabla A 48). En definitiva, 16 de las 32 variables no superan la tolerancia de 0,10. Equivalentemente, 18 de las 32 tienen una tolerancia menor o igual a 0,19 (similar a una correlación múltiple de 0,9).

Tabla A 48. Estadísticos de la variable *l_ca_ta* respecto de su colinealidad con las restantes variables.

Excluded Variable ^a								
Model	l_ca_ta	Beta In	t	Sig.	Partial Correlation	Collinearity Statistics		
						Tolerance	VIF	Minimum Tolerance
1		-434,610 ^a	-,530	,596	-,016	8,56E-010	1E+009	8,56E-010

a. Predictors in the Model: (Constant), *g_re_ta*, *l_wc_ltd*, *f_td_ce*, *l_s_wc*, *f_dp_e*, *a_cf_s*, *a_s_ta*, *t_vm*, *avvtas*, *l_wc_ta*, *v_vol250*, *g_ronfa*, *f_cf_td*, *l_i_tca*, *l_cl_tl*, *l_c_cl*, *f_td_ta*, *g_nia_ta*, *f_mve_tl*, *t_vtas*, *g_ebit_i*, *g_roe*, *l_cas_ta*, *g_ebit_a*, *f_fa_ce*, *l_cl_ta*, *g_ebit_s*, *f_ltd_ce*, *l_ca_cl*, *l_quick*, *l_cas_cl*

b. Dependent Variable: grado

D.2. Evaluación de supuestos y estadísticos de ajuste para la regresión logística binaria en la fase 1

Figura A 24. Gráficas de residuos de la regresión logística para cada capeta usada (2-cv).

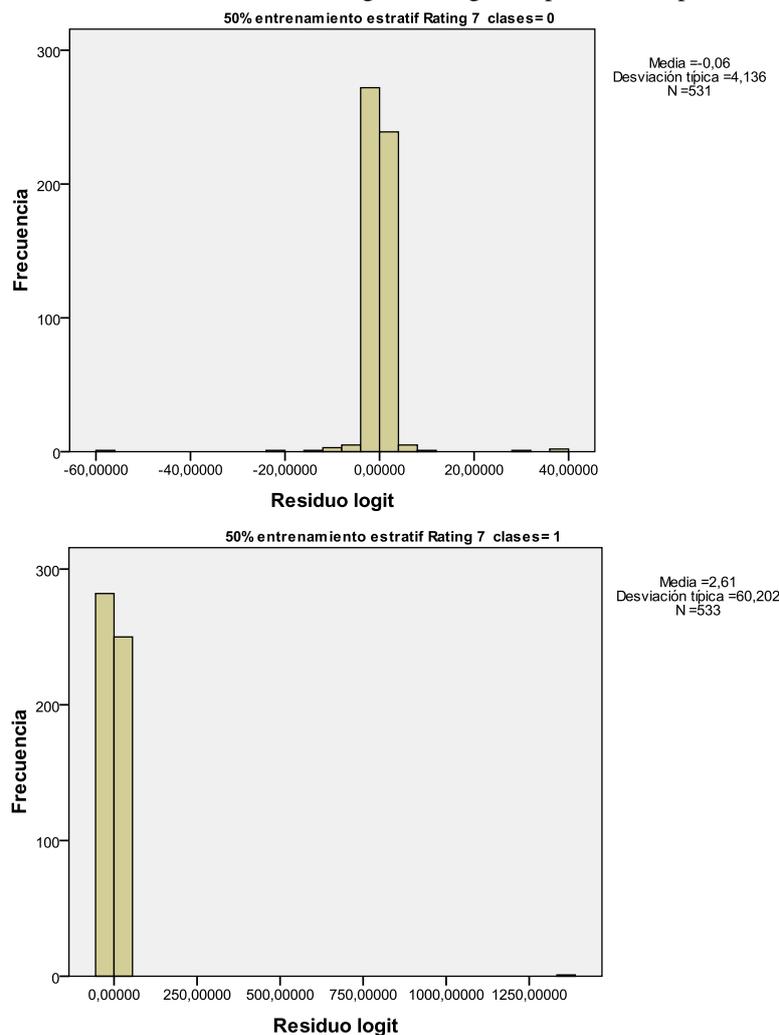


Tabla A 49. Historial de iteraciones^{a,b,c}

Iteración		-2 log de la verosimilitud	Coefficientes Constant
Paso 0	1	741,590	-,104
	2	741,590	-,105

Notas: a. En el modelo se incluye una constante. b. -2 log de la verosimilitud inicial: 741,590 . c. La estimación ha finalizado en el número de iteración 2 porque las estimaciones de los parámetros han cambiado en menos de 0,001.

Tabla A 50. Pruebas omnibus sobre los coeficientes del modelo.

		Chi cuadrado	gl	Sig.
Paso 1	Paso	481,250	31	,000
	Bloque	481,250	31	,000
	Modelo	481,250	31	,000

Tabla A 51. Resumen del modelo.

Paso	-2 log de la verosimilitud	R cuadrado de Cox y Snell	R cuadrado de Nagelkerke
1	260,340 ^a	,593	,791

Notas: a. La estimación ha finalizado en el número de iteración 13 porque las estimaciones de los parámetros han cambiado en menos de ,001.

Tabla A 52. Prueba de Hosmer y Lemeshow.

Paso	Chi cuadrado	gl	Sig.
1	11,461	8	,177

Tabla A 53. Resultados de análisis de contingencias para la prueba de Hosmer y Lemeshow

		Rating: 2 clases = grado de inversión		Rating: 2 clases = grado especulativo		Total
		Observado	Esperado	Observado	Esperado	
Paso 1	1	54	53,999	0	,001	54
	2	53	53,884	1	,116	54
	3	51	52,380	3	1,620	54
	4	51	47,267	3	6,733	54
	5	40	38,592	14	15,408	54
	6	23	24,104	31	29,896	54
	7	9	9,412	45	44,588	54
	8	1	2,128	53	51,872	54
	9	0	,234	54	53,766	54
	10	0	,001	50	49,999	50

Tabla A 54. Variables en la ecuación.

	B	E.T.	Wald	gl	Sig.	Exp(B)	I.C. 95% para EXP(B)	
							Inferior	Superior
Paso 1 ^a t_vtas	-1,056E-07	7,318E-08	2,082	1	,149	1,000	1,000	1,000
t_vm	-5,454E-07	1,290E-07	17,887	1	,000	1,000	1,000	1,000
a_sta	1,257	,407	9,552	1	,002	3,516	1,584	7,805
a_cfs	3,567	2,291	2,424	1	,119	35,414	,397	3157,340
a_vvtas	,809	,600	1,818	1	,178	2,246	,693	7,284
f_cftd	-4,568E+00	3,003	2,313	1	,128	,010	,000	3,739
f_ltdce	-7,736E-02	,137	,319	1	,572	,926	,708	1,211
f_face	,052	,074	,502	1	,478	1,054	,912	1,218
f_tdt	7,654	2,876	7,080	1	,008	2108,110	7,509	591818,693
f_dpe	-2,418E-01	,191	1,604	1	,205	,785	,540	1,142
f_mvvel	354,441	254,201	1,944	1	,163	8,546E+153	3,595E-63	.
f_tdce	-7,822E-04	,042	,000	1	,985	,999	,921	1,084
l_sw	-2,006E-03	,002	1,209	1	,272	,998	,994	1,002
l_wcltd	,000	,031	,000	1	,990	1,000	,941	1,063
l_wcta	10,521	4,624	5,178	1	,023	37103,491	4,303	3,200E+08
l_clta	-8,565E+00	7,875	1,183	1	,277	,000	3,777E-11	963,193
l_quick	-4,891E+00	1,620	9,117	1	,003	,008	,000	,180
l_casta	-1,211E+01	5,270	5,282	1	,022	,000	1,791E-10	,168
l_casl	4,370	1,802	5,881	1	,015	79,082	2,312	2704,680
l_cacl	,150	,943	,025	1	,873	1,162	,183	7,378
l_ccl	,655	,601	1,189	1	,276	1,925	,593	6,248
l_itca	-2,582E+00	2,334	1,224	1	,268	,076	,001	7,327
l_cltl	7,134	4,787	2,221	1	,136	1253,852	,106	1,490E+07
g_ebiti	-7,959E-02	,058	1,892	1	,169	,923	,824	1,034
g_niata	10,378	6,266	2,743	1	,098	32136,284	,149	6,931E+09
g_ebits	-2,189E+00	1,485	2,172	1	,141	,112	,006	2,058
g_ronfa	,534	,352	2,303	1	,129	1,706	,856	3,400
g_ebita	-1,157E+01	8,046	2,067	1	,150	,000	1,339E-12	66,753
g_roe	-3,010E-01	,208	2,085	1	,149	,740	,492	1,114
g_reta	-2,721E+00	,786	11,989	1	,001	,066	,014	,307
v_vol250	,071	,013	31,416	1	2,083E-08	1,074	1,047	1,100
Constante	-7,079E+00	2,433	8,468	1	,004	,001		

Nota: a. Variable(s) introducida(s) en el paso 1: t_vtas, t_vm, a_sta, a_cfs, a_vvtas, f_cftd, f_ltdce, f_face, f_tdt, f_dpe, f_mvvel, f_tdce, l_sw, l_wcltd, l_wcta, l_clta, l_quick, l_casta, l_casl, l_cacl, l_ccl, l_itca, l_cltl, g_ebiti, g_niata, g_ebits, g_ronfa, g_ebita, g_roe, g_reta, v_vol250.

D.3. Análisis de supuestos de análisis discriminante usados en la fase 2 y que difiere de la fase 1

Tabla A 55. Resumen del procesamiento de los casos

		N	% marginal
R_lpmln2	AAA,AA	29	4,3%
	A	121	17,9%
	BBB	206	30,5%
	BB	169	25,0%
	B	115	17,0%
	C	25	3,7%
	D	11	1,6%
Válidos		676	100,0%
Perdidos		0	
Total		676	

Tabla A 56. Resumen del procesamiento para el análisis de casos

Casos no ponderados		N	Porcentaje
Válidos		676	100,0
Excluidos	Códigos de grupo para perdidos o fuera de rango	0	,0
	Perdida al menos una variable discriminante	0	,0
	Perdidos o fuera de rango ambos, el código de grupo y al menos una de las variables discriminantes.	0	,0
	Total excluidos	0	,0
Casos Totales		676	100,0

Tabla A 57. Pruebas de igualdad de las medias de los grupos

	Lambda de Wilks	F	gl1	gl2	Sig.
t_vtas	,838	21,508	6	669	,000
t_vm	,661	57,154	6	669	,000
a_s-ta	,975	2,868	6	669	,009
a_cf-s	,980	2,302	6	669	,033
a_vvtas	,985	1,747	6	669	,108
f_cf-td	,831	22,676	6	669	,000
f_ltd-ce	,987	1,500	6	669	,176
f_fa-ce	,989	1,250	6	669	,279
f_td-ta	,812	25,829	6	669	,000
f_dp-e	,989	1,208	6	669	,300
f_mve-tl	,843	20,750	6	669	,000
f_td-ce	,988	1,328	6	669	,242
l_s-wc	,997	,288	6	669	,943
l_wc-ltd	,987	1,484	6	669	,181
l_wc-ta	,914	10,537	6	669	,000
l_cl-ta	,940	7,087	6	669	,000
l_quick	,944	6,649	6	669	,000
l_cas-ta	,960	4,618	6	669	,000
l_cas-cl	,942	6,811	6	669	,000
l_ca-cl	,942	6,919	6	669	,000
l_c-cl	,938	7,353	6	669	,000
l_i-tca	,961	4,534	6	669	,000
l_ca-ta	,971	3,293	6	669	,003
l_cl-tl	,964	4,113	6	669	,000
g_ebit-i	,967	3,775	6	669	,001
g_nia-ta	,847	20,195	6	669	,000
g_ebit-s	,973	3,117	6	669	,005
g_ronfa	,958	4,829	6	669	,000
g_ebit-a	,795	28,819	6	669	,000
g_roe	,965	3,986	6	669	,001
g_re-ta	,837	21,686	6	669	,000
v_vol250	,419	154,822	6	669	,000

Tabla A 58. Prueba de Box sobre la igualdad de las matrices de covarianza

Logaritmo de los determinantes		
R_lpmln2	Rango	Logaritmo del determinante
AAA,AA	.a	.b
A	31	-22,551
BBB	31	-10,080
BB	31	2,218
B	31	40,586
C	.c	.b
D	.d	.b
Intra-grupos combinada	31	45,867

Notas: Los rangos y logaritmos naturales de los determinantes impresos son los de las matrices de covarianzas de los grupos. (a). Rango < 29. (b). Muy pocos casos para ser no-singular. (c). Rango < 25. (d). Rango < 11.

Tabla A 59. Resultados de la prueba M de Box^a

M de Box		29444,261
F	Aprox.	17,915
	gl1	1488
	gl2	549645,093
	Sig.	,000

Nota: Contrasta la hipótesis nula de que las matrices de covarianzas poblacionales son iguales.

a. Algunas matrices de covarianzas son singulares y el procedimiento ordinario no es válido. Los grupos no singulares se compararán con sus propias matrices de covarianzas intra-grupo combinadas. El logaritmo de su determinante es 48,882.

Tabla A 60. Variables que no pasan la prueba de tolerancia^a

	Varianza intra-grupo	Tolerancia	Tolerancia mínima
l_ca-ta	,039	,000	,000

Nota: a. El nivel de tolerancia mínimo es ,001. Todas las variables que cumplan los criterios de tolerancia se introducen simultáneamente.

Resumen de las funciones canónicas discriminantes

Tabla A 61. Autovalores

Función	Autovalor	% de varianza	% acumulado	Correlación canónica
1	2,024 ^a	64,5	64,5	,818
2	,605 ^a	19,3	83,8	,614
3	,275 ^a	8,8	92,5	,465
4	,139 ^a	4,4	96,9	,349
5	,061 ^a	1,9	98,9	,239
6	,036 ^a	1,1	100,0	,186

Tabla A 62. Lambda de Wilks

Contraste de las funciones	Lambda de Wilks	Chi-cuadrado	gl	Sig.
1 a la 6	,129	1342,431	186	,000
2 a la 6	,391	616,593	150	,000
3 a la 6	,627	306,133	116	,000
4 a la 6	,800	146,672	84	,000
5 a la 6	,910	61,551	54	,224
6	,966	22,984	26	,634

Tabla A 63. Resultados de la prueba M de Box

M de Box		2516,580
F	Aprox.	18,348
	gl1	126
	gl2	13471,501
	Sig.	,000

Esta prueba M de Box contrasta la hipótesis nula de que las matrices de covarianzas pertenecen a poblaciones iguales para las funciones canónicas discriminantes.

Tabla A 64. Funciones en los centroides de los grupos

R_lpm1n2	Función					
	1	2	3	4	5	6
AAA,AA	-2,105	3,031	-,716	,380	-,272	,145
A	-1,091	,208	,213	-,099	,241	-,309
BBB	-,686	-,218	,234	-,207	,073	,220
BB	,108	-,485	,149	,274	-,331	-,073
B	1,401	-,282	-,840	,215	,222	,025
C	3,267	,856	-,340	-1,457	-,416	-,156
D	6,673	2,262	2,424	,821	,405	,124

Nota: Funciones discriminantes canónicas no tipificadas evaluadas en las medias de los grupos.

Tabla A 65. Coeficientes estandarizados de las funciones discriminantes canónicas

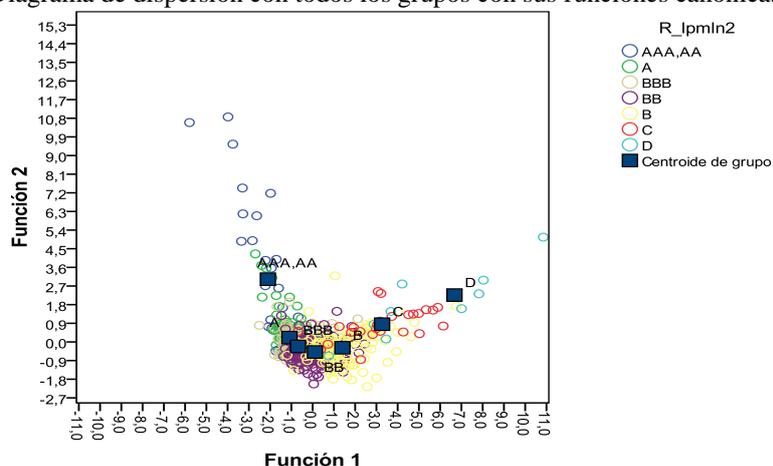
	Función					
	1	2	3	4	5	6
t_vtas	-,134	,059	,280	-,182	,467	,295
t_vm	-,182	,711	-,477	,385	-,516	-,046
a_s-ta	-,014	-,164	-,226	,307	-,477	,755
a_cf-s	,675	,520	-,880	-,586	-1,294	,809
a_vvtas	,125	-,061	-,085	-,314	-,213	,189
f_cf-td	-,066	,005	,289	-,053	-,010	-,070
f_ltd-ce	,480	-,008	,280	,899	,546	,021
f_fa-ce	,191	,388	-,108	-,974	,077	-,218
f_td-ta	,533	,373	-,354	-,162	,103	-,005
f_dp-e	-,015	,032	,052	-,088	,109	,285
f_mv-e-tl	-,137	,282	,210	,051	,297	-,498
f_td-ce	-,599	-,357	-,246	,092	-,743	,111
l_s-wc	,059	-,128	,003	,056	,054	,039
l_wc-ltd	-,081	,204	-,107	-,063	,380	,112
l_wc-ta	,312	-,319	-,289	,417	-,318	-,864
l_cl-ta	-,290	-,393	1,296	,617	-,100	-,956
l_quick	-,604	3,788	2,085	-2,120	3,932	5,714
l_cas-ta	-,296	-,023	-,038	-,300	,375	,650
l_cas-cl	-,070	-3,024	-1,171	1,918	-3,835	-6,356
l_ca-cl	,511	,137	,306	1,398	-,221	,664
l_c-cl	,323	-,823	-1,447	-1,002	,375	,142
l_i-tca	-,141	,001	,260	-,236	-,064	-,208
l_cl-tl	,354	,520	-,941	-,486	,178	,153
g_ebit-i	-,089	,321	-,125	-,204	,273	,038
g_nia-ta	-,110	-,258	-,873	,152	,736	,015
g_ebit-s	-,701	-,514	,827	,647	1,291	-,766
g_ronfa	,010	,030	-,322	-,121	-,302	,199
g_ebit-a	,438	,457	1,367	,096	-,645	,208
g_roe	,076	,203	,248	-,351	-,291	-,139
g_re-ta	-,275	-,141	,036	,372	,379	,025
v_vol250	,953	,338	,250	,227	,032	,076

Tabla A 66. Prueba de Box sobre la igualdad de las matrices de covarianzas de las funciones canónicas discriminantes.

Logaritmo de los determinantes		
R_ipmln2	Rango	Logaritmo
AAA,AA	6	0,432
A	6	-6,179
BBB	6	-5,342
BB	6	-4,593
B	6	0,638
C	6	0,179
D	6	0,242
matriz identidad	6	0

Nota: Los rangos y logaritmos naturales de los determinantes impresos son los de las matrices de covarianzas de los grupos de las funciones canónicas discriminantes.

Figura A 25. Diagrama de dispersión con todos los grupos con sus funciones canónicas discriminantes



D.4. Evaluación de supuestos y estadísticos de ajuste para la regresión logística multinomial en la fase 2 y que difiere de la fase 1.

Figura A 26. Histograma de los residuos de rogresión logística multinomial en la fase 2 de una de las (k-1) carpetas.

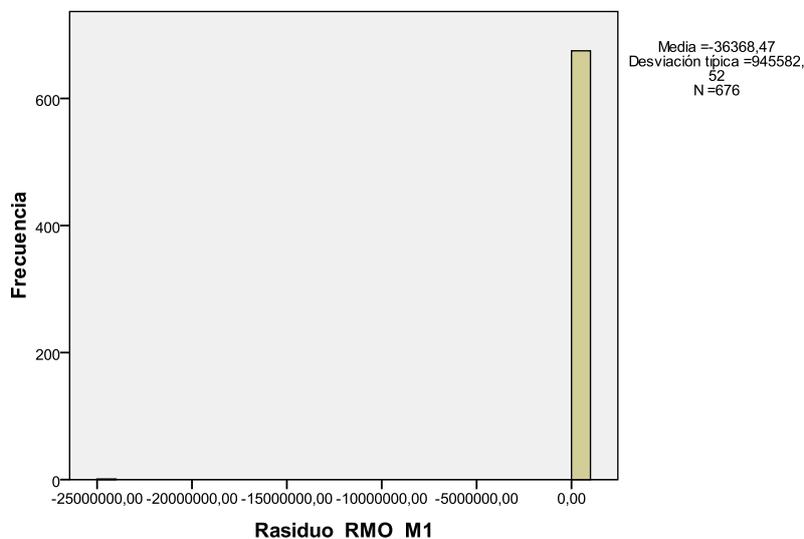


Tabla A 67. Resumen del procesamiento de los casos

		N	Porcentaje marginal
R_lpmln2	AAA,AA	29	4,3%
	A	121	17,9%
	BBB	206	30,5%
	BB	169	25,0%
	B	115	17,0%
	C	25	3,7%
	D	11	1,6%
Válidos		676	100,0%
Perdidos		0	
Total		676	

Tabla A 68. Información del ajuste del modelo

Modelo	Criterio de ajuste del modelo			Contrastes de la razón de verosimilitud		
	AIC	BIC	-2 log verosimilitud	Chi-cuadrado	gl	Sig.
Sólo la intersección	2231,986	2259,083	2219,986			
Final	1413,430	2280,539	1029,430	1190,556	186	5,325E-146

Tabla A 69. Bondad del ajuste

	Chi-cuadrado	gl	Sig.
Pearson	2655,640	3864	1,000
Desviación	1029,430	3864	1,000

Tabla A 70. Pseudo R-cuadrado

Cox y Snell	,828
Nagelkerke	,860
McFadden	,536

Tabla A 71. Contrastes de la razón de verosimilitud

Efecto	Criterio de ajuste del modelo			Contrastes de la razón de verosimilitud		
	AIC de modelo reducido	BIC de modelo reducido	-2 log verosimilitud del modelo reducido	Chi-cuadrado	gl	Sig.
Intersección	1434,053	2274,065	1062,053	32,623	6	,000
t_vtas	1416,909	2256,921	1044,909	15,479	6	,017
t_vm	1484,113	2324,125	1112,113	82,683	6	9,963E-16
a_sta	1406,908	2246,920	1034,908	5,478	6	,484
a_cfs	1427,792	2267,804	1055,792	26,362	6	,000
a_vvtas	1414,859	2254,871	1042,859	13,429	6	,037
f_cftd	1412,271	2252,283	1040,271	10,841	6	,093
f_ltde	1402,993	2243,004	1030,993	1,562	6	,955
f_face	1401,392	2241,404	1029,392	.	6	.
f_tda	1411,375	2251,387	1039,375	9,945	6	,127
f_dpe	1402,152	2242,164	1030,152	,722	6	,994
f_mvctl	1402,857	2242,869	1030,857	1,427	6	,964
f_tde	1407,790	2247,802	1035,790	6,360	6	,384
l_swc	1412,483	2252,495	1040,483	11,053	6	,087
l_wcltd	1401,972	2241,984	1029,972	,542	6	,997
l_wcta	1413,430	2280,539	1029,430	,000	0	.
l_clta	1413,430	2280,539	1029,430	,000	0	.
l_quick	1412,370	2252,382	1040,370	10,940	6	,090
l_casta	1405,233	2245,245	1033,233	3,803	6	,703
l_casl	1415,617	2255,629	1043,617	14,187	6	,028
l_cacl	1403,954	2243,966	1031,954	2,524	6	,866
l_ccl	1410,328	2250,340	1038,328	8,898	6	,179
l_itca	1408,309	2248,321	1036,309	6,879	6	,332
l_cata	1413,430	2280,539	1029,430	,000	0	.
l_cltl	1417,040	2257,052	1045,040	15,610	6	,016
g_ebiti	1418,655	2258,666	1046,655	17,224	6	,008
g_niata	1429,750	2269,762	1057,750	28,320	6	,000
g_ebits	1411,132	2251,144	1039,132	9,702	6	,138
g_ronfa	1413,593	2253,605	1041,593	12,163	6	,058
g_ebita	1413,922	2253,934	1041,922	12,491	6	,052
g_roe	1407,683	2247,695	1035,683	6,253	6	,396
g_reta	1455,285	2295,297	1083,285	53,855	6	7,891E-10
v_vol250	1495,021	2335,032	1123,021	93,590	6	5,433E-18

Notas: El estadístico de chi-cuadrado es la diferencia en las -2 log verosimilitudes entre el modelo final y el modelo reducido. El modelo reducido se forma omitiendo un efecto del modelo final. La hipótesis nula es que todos los parámetros de ese efecto son 0.

- Se han encontrado singularidades inesperadas en la matriz Hessiana. Esto indica que se deberán excluir algunas variables predictoras o que se deberán fusionar algunas categorías.
- Es posible que haya una separación casi completa de los datos. O bien no existen estimaciones de máxima verosimilitud o bien algunas estimaciones de parámetros son infinitas.
- Este modelo reducido es equivalente al modelo final ya que la omisión del efecto no incrementa los grados de libertad.

Anexo E. Calibración de parámetros y réplica con SVM

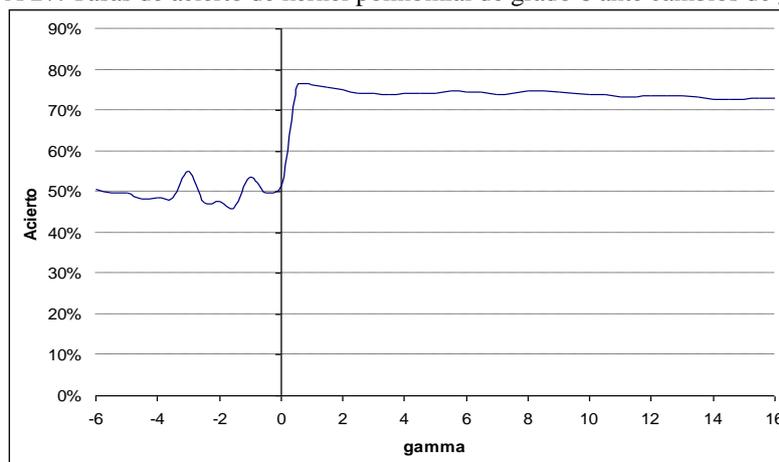
E.1. Calibración de parámetros en la fase 1.

En el análisis de la sensibilidad de cada parámetro se determinaron:

- las cotas superior e inferior en función de los valores que podrían maximizar los niveles de acierto, y
- entre estos límites se estableció un incremento pequeño del parámetro analizado para evaluar las posibles tasas de acierto y error que se obtienen de la réplica.

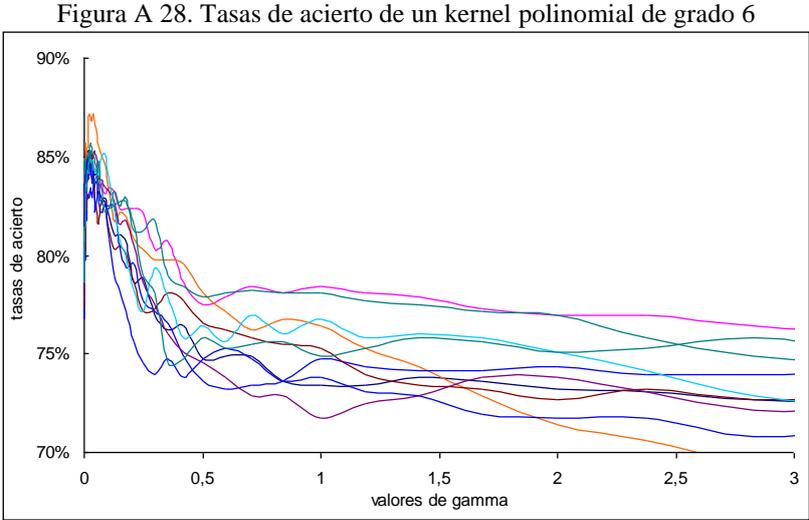
Siguiendo a Hsu, Chan y Lin (2010) y Lin y Lin (2003), los límites utilizados fueron desde $2^{-\eta}$ hasta 2^{θ} , con pequeños incrementos de δ . Aunque la regla general ofrecida por estos autores es buscar el óptimo entre 2^{-15} y 2^{15} , los valores de η , θ , y δ fueron distintos para cada kernel en función del comportamiento del nivel de acierto y del coste de cálculo (en tiempo y en recursos computacionales). Por ejemplo, para dimensionar la sensibilidad de gamma en el kernel polinomial de grado 6, los valores de η y θ fueron -20 y 20 con lo cual la amplitud de valores es bastante grande, es decir, entre $[2^{-20}; 2^{20}]$. Sin embargo, se pudo observar que un rango que describía mejor los potenciales valores que maximizarían las tasas de acierto estaba entre $[-6; 16]$, ya que fuera de este rango las tasas de acierto no cambian significativamente y el algoritmo de optimización de la SVM presenta un esfuerzo excesivo para encontrar los vectores soportes que clasifiquen los ratings. La Figura A 27 muestra este caso, donde se observa un fuerte incremento de la tasa de acierto a partir de $\text{gamma} > 0$, pero que se detiene en $\text{gamma} > 1$.

Figura A 27. Tasas de acierto de kernel polinomial de grado 6 ante cambios de gamma.



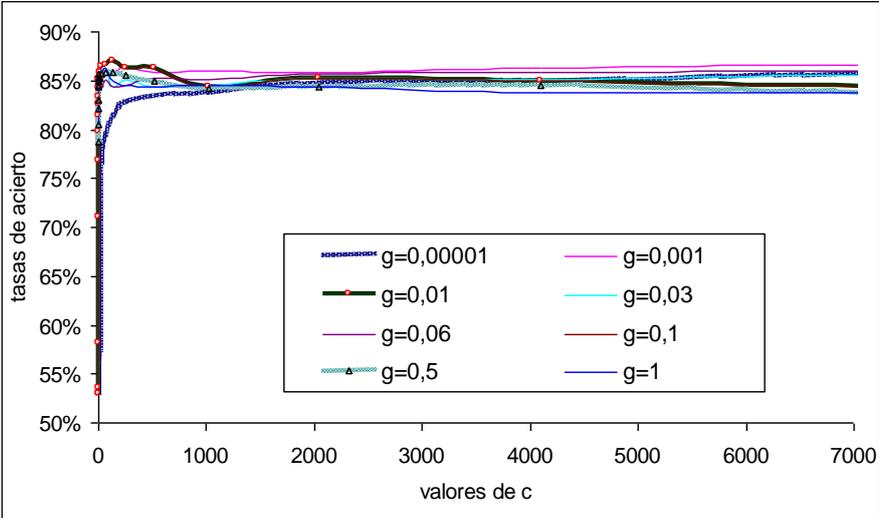
Para verificar cual era el valor del parámetro que maximizaba la tasa de aciertos para un parámetro en particular, se realizó el cálculo sucesivo en 10 oportunidades de las tasas de acierto con distintos valores del parámetro, calculando la media del valor del parámetro que maximizaba en cada

oportunidad la tasa de aciertos. La Figura A 28 grafica los resultados de estas 10 iteraciones para el valor de gamma en un kernel polinomial de grado 6, encontrando que en promedio el valor de gamma que maximiza el nivel de acierto es 0,03325. La siguiente figura expone esta situación.



Sin embargo, debido a la relación que existe entre los distintos parámetros, especialmente en los kernels polinómicos, la obtención de cada parámetro óptimo se realizó analizando la dependencia que existía entre ellos. Los parámetros que guardaron más dependencia fueron gamma, el coeficiente r y el grado d de la función polinomial. La relación entre el valor de C y gamma que se observó en la muestra permite confirmar la independencia entre ambos parámetros, sólo para los kernels polinómicos. Como se puede observar en la Figura A 30 y Figura A 31, el valor de gamma parece bastante independiente del valor de C para determinar las tasas de acierto máximas. Es decir, el valor que tome C no influye en la decisión para elegir gamma. Sólo cuando gamma se acerca mucho a 0, entonces el valor que tome C es más relevante.

Figura A 29. Relación entre gamma y C para el kernel polinomial de 2º grado respecto de las tasas de acierto.



En cambio, tanto en el kernel sigmoide como en el gaussiano la relación de independencia es menos fuerte cuando gamma tiende a cero. A pesar de ello, en la mayoría de los tramos la elección de un valor de C no condiciona el gamma óptimo.

Figura A 30. Relación entre gamma y C para el kernel sigmoide respecto de las tasas de acierto.

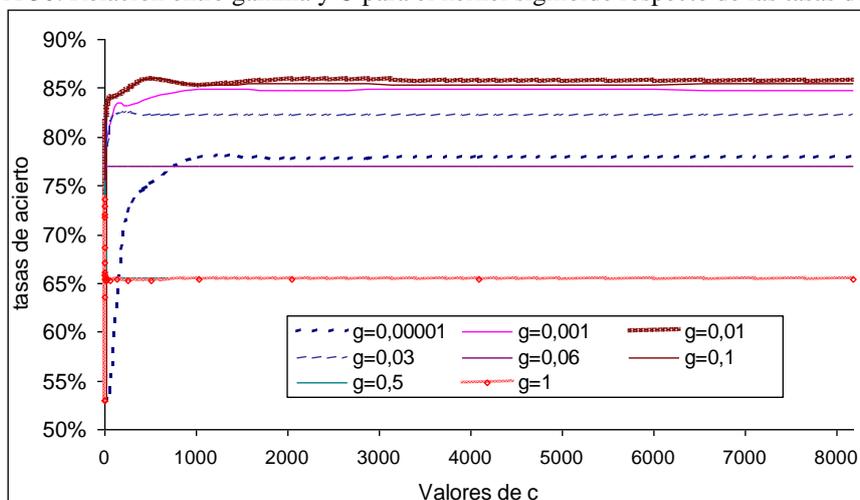
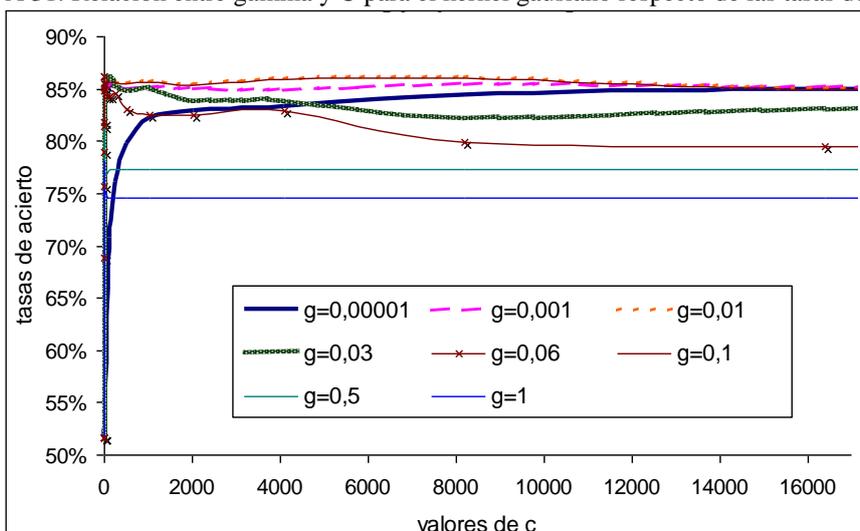


Figura A 31. Relación entre gamma y C para el kernel gaussiano respecto de las tasas de acierto.



Luego de analizar cada una de las relaciones entre los parámetros y las tasas de acierto, se calcularon aquellos valores que maximizaban a estas últimas. El resultado de este análisis se presenta a continuación para cada uno de las funciones núcleo.

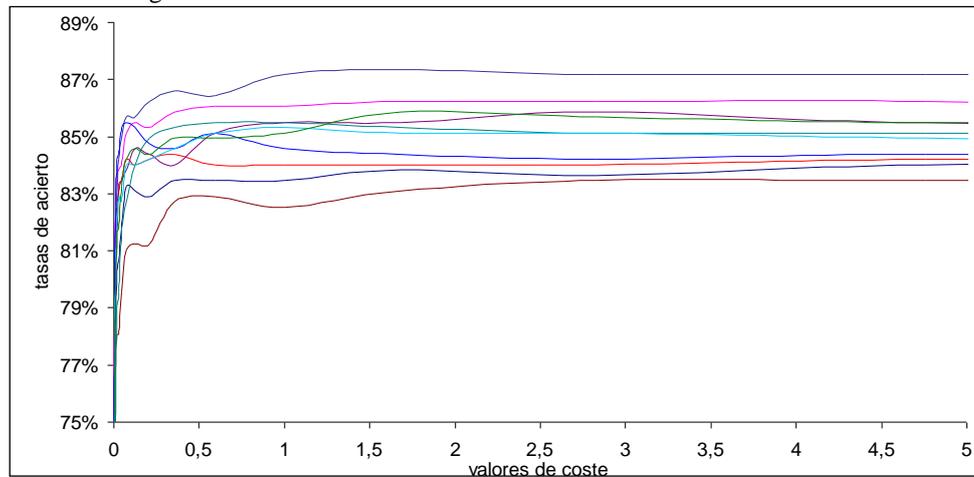
A) Kernel lineal

Para esta función núcleo el rango del costo (c) considerado fue

$$\begin{array}{lcl}
 \eta = & -12 & \\
 \phi = & 9 & \implies c = [0,000244 ; 512], \\
 \delta = & 3/4 &
 \end{array}$$

lográndose el máximo nivel de aciertos (promedio) de 85,4% cuando el parámetro C tuvo como media 2,8107. La Figura A 32 muestra las tasas de acierto con 10 iteraciones para distintos valores de C .

Figura A 32. Tasas de acierto del kernel lineal ante cambio del coste.



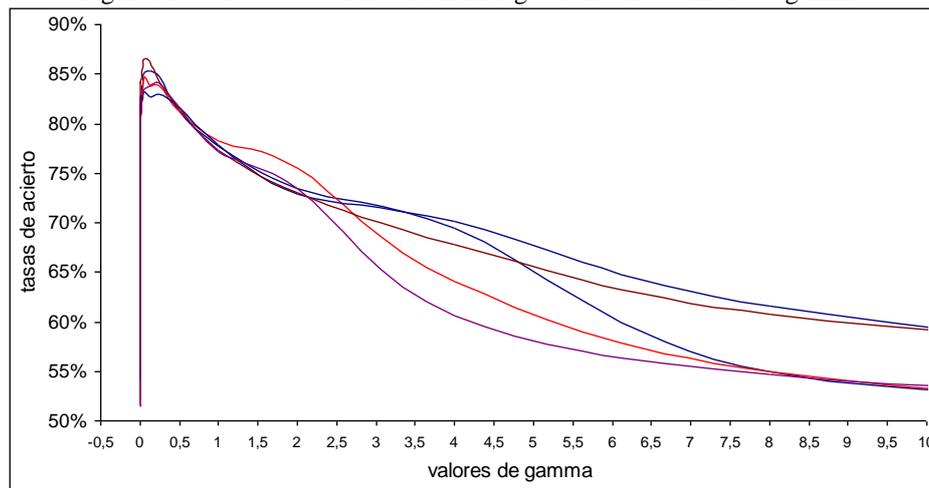
B) Kernel gaussiano o radial

Para el kernel gaussiano, primero se supuso un valor de C pequeño y distinto de cero, por lo que el valor de gamma (g) óptimo se calculó dentro del rango

$$\begin{array}{l} \eta = -15 \\ \phi = 15 \\ \delta = 1 \end{array} \quad \implies \quad \text{gamma} = [0,0000305 ; 32.768],$$

lográndose el máximo nivel de aciertos (en promedio) de 84,8% cuando el valor de gamma, en promedio, fue de 0,1125. La Figura A 33 expone la distribución de tasas de acierto cuando cambia gamma, graficando que el máximo nivel de aciertos (cerca del 85%) está cuando $g=0,11$.

Figura A 33. Tasas de acierto del kernel gaussiano ante cambio de gamma.

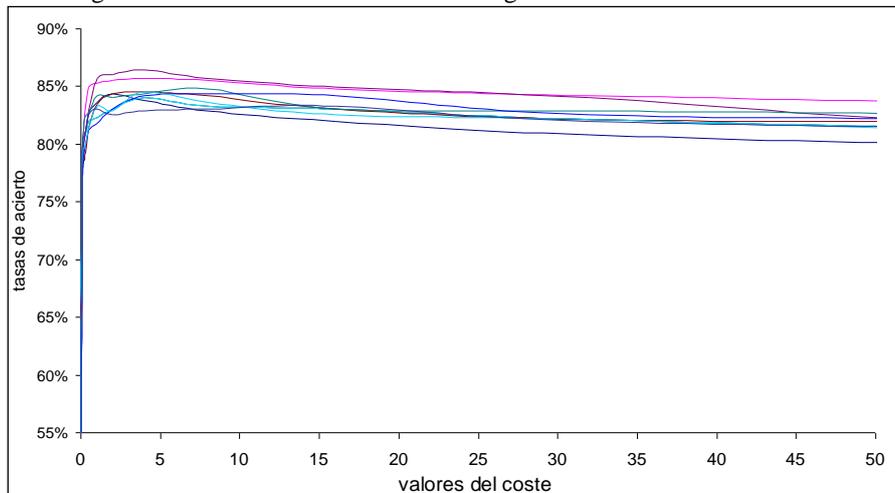


Luego, si el gamma óptimo es $g=0,1$, el rango del costo (C) para encontrar su óptimo fue

$$\begin{array}{l} \eta = -12 \\ \phi = 9 \\ \delta = 1 \end{array} \quad \implies \quad c = [0,00001529 ; 32.768],$$

logrando el máximo nivel de aciertos de 84,6% cuando C tuvo un valor medio de 5,8. Los resultados de estos cálculos se exponen en la Figura A 34.

Figura A 34. Tasas de acierto del kernel gaussiano ante cambio del coste.



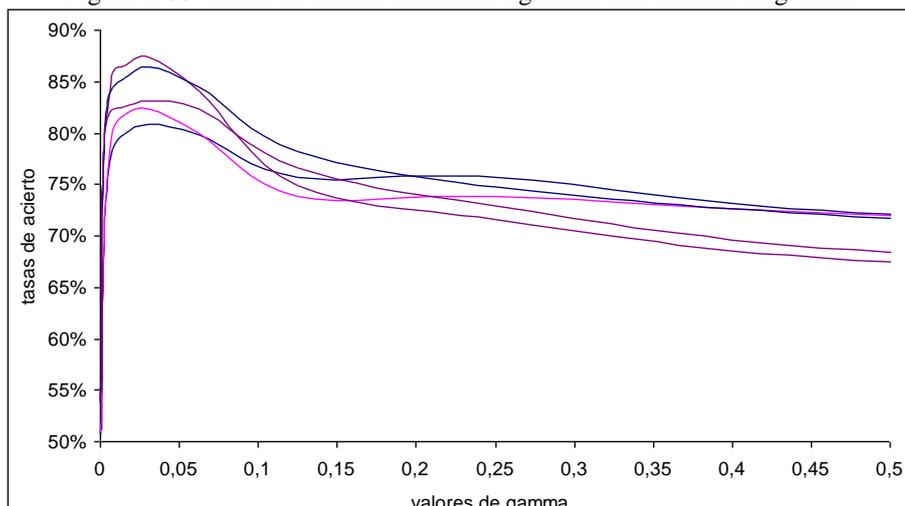
C) Kernel sigmoide

Para el kernel sigmoide se inició el proceso de sensibilidad suponiendo que el coeficiente $r = 0$, $C = 1$ y el rango en el que gamma (γ) puede ser óptima es

$$\begin{array}{l} \eta = -14 \\ \phi = 14 \\ \delta = 1 \end{array} \implies \text{gamma} = [0,000061; 16.384]$$

obteniéndose el máximo nivel de aciertos (en promedio) de 84,0% cuando gamma tenía en promedio un valor $\gamma = 0,0313$, tal y como se grafica en la Figura A 35.

Figura A 35. Tasas de acierto del kernel sigmoide ante cambio de gamma.



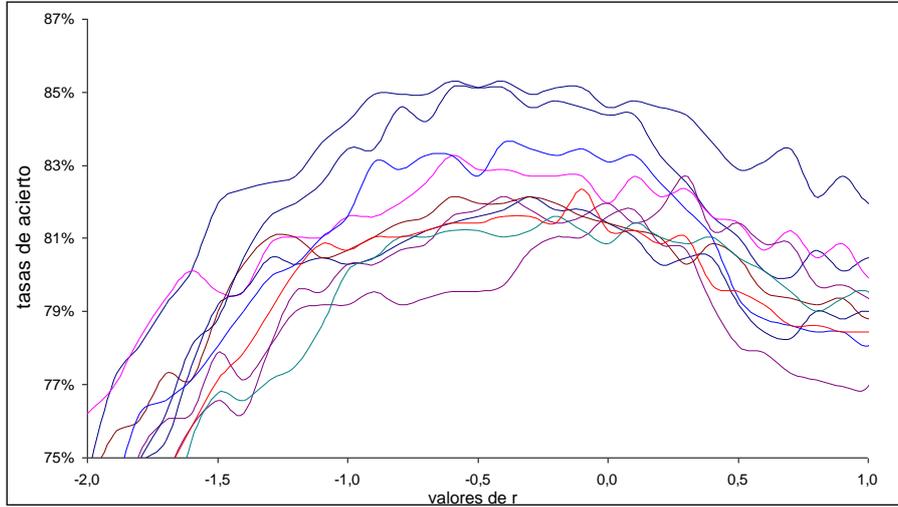
Luego, si el gamma óptimo es igual 0,0313 y $C = 1$, el rango del coeficiente r para encontrar el valor que maximice la tasas de aciertos fue

$$\eta = -2$$

$$\begin{aligned} \phi &= 2 & \implies & \text{coeficiente } (r) = [-2 ; 2] \\ \delta &= 1/10 \end{aligned}$$

lográndose el máximo nivel de aciertos (en promedio) de 83,0% cuando el valor medio de $r = -0,2800$, lo que observa en la Figura A 36.

Figura A 36. Tasas de acierto del kernel sigmoide ante cambios de r .

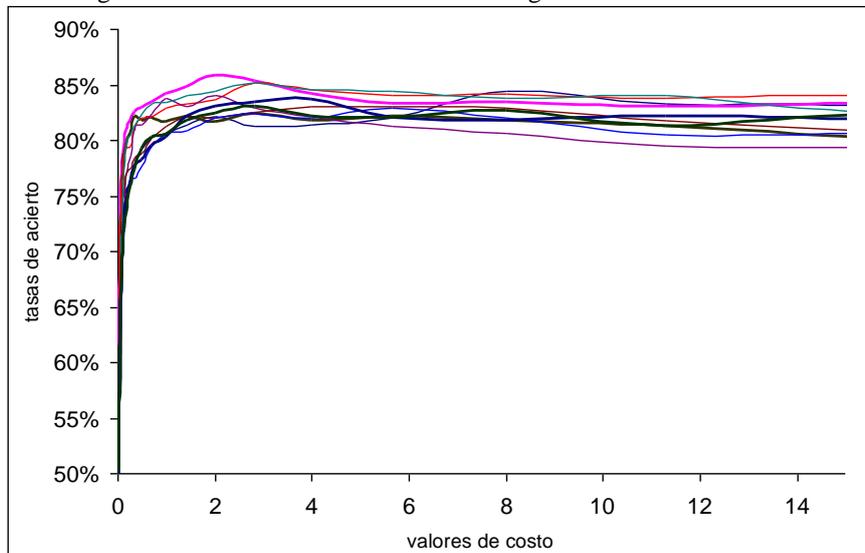


Finalmente, dado que se calcularon los valores óptimos de γ y r , sólo resto calcular el valor óptimo para c . Para ello, el rango inicial donde se buscó el óptimo que maximizara la tasa de aciertos fue

$$\begin{aligned} \eta &= -14 \\ \phi &= 14 & \implies & c = [6,10352E-05; 16.384], \\ \delta &= 1/2 \end{aligned}$$

obteniéndose el máximo nivel de aciertos (en promedio) de 83,96% cuando C tenía en promedio un valor $C = 1,75$, tal y como se grafica en la Figura A 37.

Figura A 37. Tasas de acierto del kernel sigmoide ante cambios de r .



D) Kernel polinomial

Para las funciones núcleo de tipo polinomial el análisis de la sensibilidad se ha separado primero por el grado de la forma funcional (d). Luego en cada kernel diferenciado por su grado se presentan los resultados de la sensibilidad de los restantes parámetros.

D.1) Kernel Polinomial de grado 1

Para el primer grado polinomial de este kernel el efecto de la constante r en la tasa de acierto es nula. Es decir, no importa el valor que toma r , ya que el acierto dependerá del valor de γ y del costo. La Tabla A 72 ilustra las diferencias entre tasas de acierto calculadas a distintos valores de r , y en todas ellas la diferencia es nula.

Tabla A 72. Diferencia entre tasas de acierto ante cambios de la constante r .

valores de r (?) \ valores de γ (?)	$\gamma = 0,000001$	$\gamma = 0,1$	$\gamma = 100$
r entre -2 y 2 con intervalos de 0,1	0	0	0
r entre -20 y 20 con intervalos de 1	0	0	0
r entre -200 y 200 con intervalos de 10	0	0	0
r entre -20000 y 20000 con intervalos de 1000 (*)	0	0	0

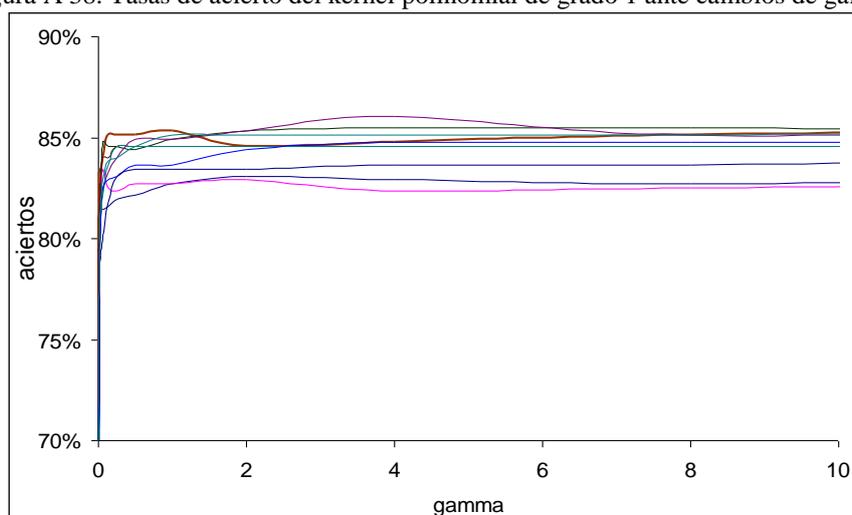
NOTA: (*) en este caso corresponde a la suma de las diferencias entre los porcentajes de acierto.

Luego, el cálculo del valor óptimo de γ para este kernel se estableció con

$$\begin{array}{lcl} \eta = & -15 & \\ \phi = & 15 & \implies c = [3,05176E-05 ; 32.768], \\ \delta = & 1 & \end{array}$$

obteniéndose el máximo nivel de aciertos (en promedio) de 84,68% cuando γ tenía en promedio un valor $\gamma = 1,75$, tal y como se grafica en la Figura A 38.

Figura A 38. Tasas de acierto del kernel polinomial de grado 1 ante cambios de γ .

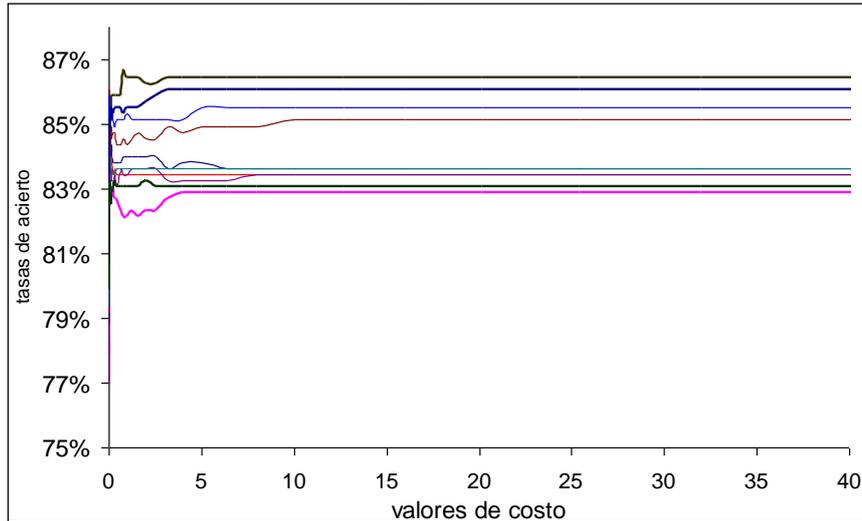


Finalmente, el cálculo del valor óptimo de C se estableció entre los siguientes límites

$$\begin{array}{lcl} \eta = & -10 & \\ \phi = & 10 & \implies c = [0,000976563 ; 128], \\ \delta = & 1 & \end{array}$$

obteniéndose el máximo nivel de aciertos (en promedio) de 84,85% cuando el costo tenía, en promedio, un valor $c = 0,42$, tal y como se grafica en la Figura A 39.

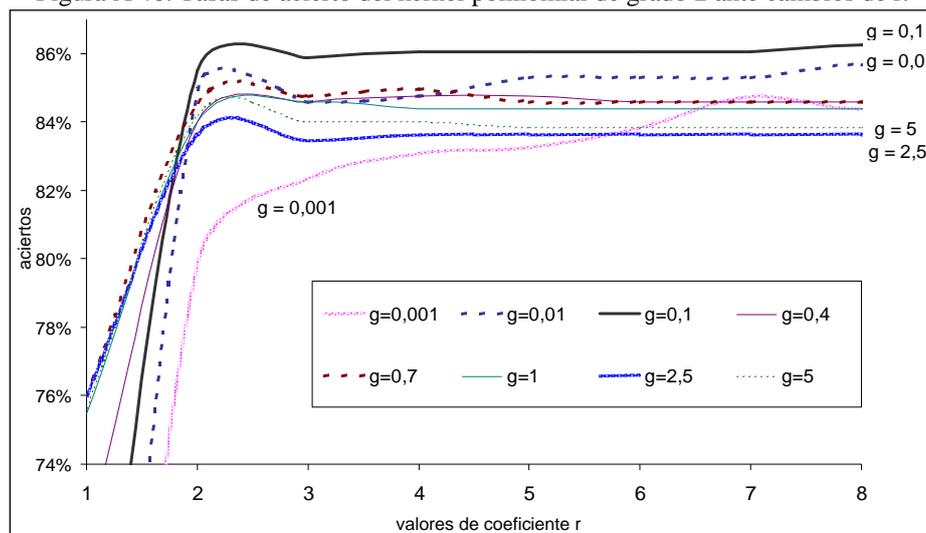
Figura A 39. Tasas de acierto del kernel polinomial de grado 1 ante cambios del coste.



D.2) Kernel Polinomial de grado 2

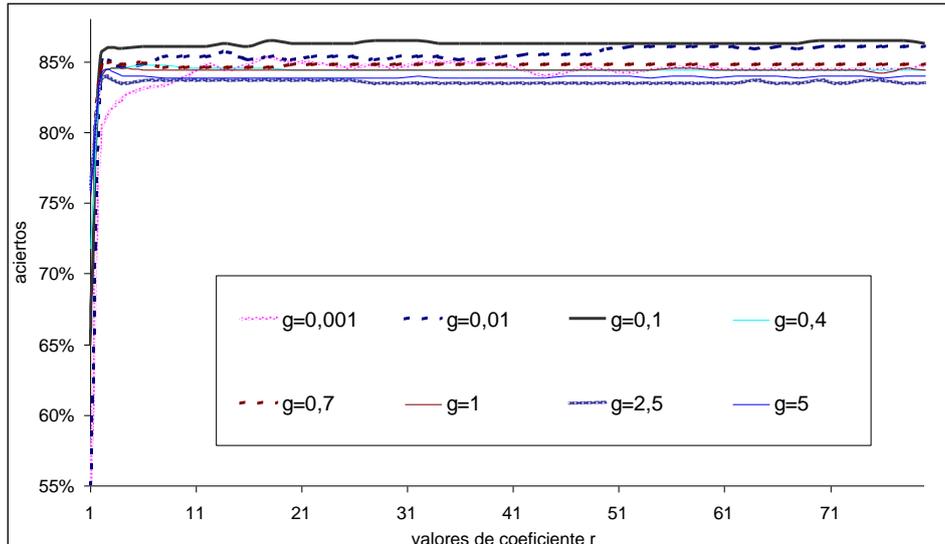
El nivel de aciertos obtenido con un kernel polinomial de grado 2 varía según el valor r y γ de la siguiente forma: a partir de $r > 2$ el mayor nivel de aciertos se logran con $\gamma \rightarrow 0,1$, pero con $r < 2$ los mayores aciertos se logran con $\gamma > 0,1$, tal y como se grafica en la Figura A 40 y en la Figura A 41.

Figura A 40. Tasas de acierto del kernel polinomial de grado 2 ante cambios de r .



Por otra parte, el valor de r que maximiza el nivel de aciertos, debería ser mayor 2 para cualquier valor de γ . En general, si $r > 10$ el nivel de aciertos crece muy poco o nada (Figura A 41).

Figura A 41. Tasas de acierto del kernel polinomial de grado 2 ante cambios de gamma.



Finalmente, el cálculo del valor óptimo de C se estableció entre los siguientes límites

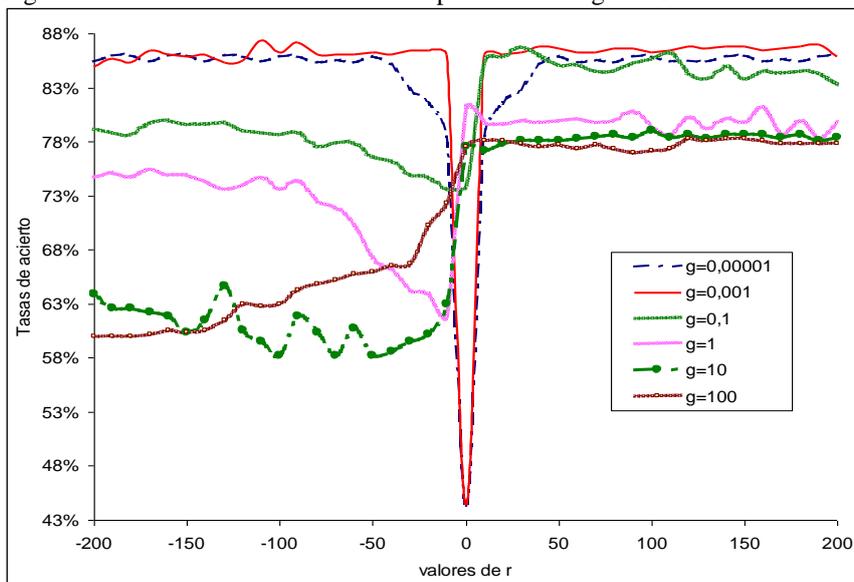
$$\begin{array}{l} \eta = -10 \\ \phi = 10 \\ \delta = 1 \end{array} \quad \implies \quad c = [0,000976563 ; 128],$$

obteniéndose el máximo nivel de aciertos (en promedio) de 85,63% cuando el costo tenía, en promedio, un valor $c = 0,82$.

D.3) Kernel Polinomial de grado 3

Para el kernel polinomial de tercer grado, en la medida que $r \rightarrow 0$ el nivel de aciertos disminuye a casi la mitad de la tasa de aciertos máxima. La magnitud de esta diferencia y del rango de r que permite maximizar el grado de aciertos depende del valor que tome gamma (ver Figura A 42).

Figura A 42. Tasas de acierto del kernel polinomial de grado 3 ante cambios de r.



La distribución de aciertos es relativamente isométrica respecto de r cuando γ tiene un valor muy pequeño. En la figura esto se aprecia cuando $0 < \gamma \leq 0,001$, y cuando $\gamma = 0,00001$ y $r =]-40, 40[$ el nivel de aciertos baja significativamente (hasta aciertos del 45%). En la medida que γ aumenta levemente, el rango en que los valores de r minimizan los aciertos disminuye. En la figura se puede observar que para $\gamma = 0,001$, el rango de r con menores tasas de aciertos se encuentra entre $]-10, 10[$.

Para otros valores de γ la isometría de las distribuciones de tasas de acierto desaparece, a pesar de que la menor tasa de aciertos continúa siendo baja cuando $r = 0$. Cuando $\gamma = 0,1$, las mayores tasas de acierto se logran cuando $r > 0$ y se maximizan cuando $r \rightarrow 10$. Sin embargo, cuando $\gamma = 1$ se percibe una pequeña disminución en las tasas de acierto cuando $r > 20$.

Similar isometría se puede observar en la distribución de aciertos cuando $\gamma \geq 1$. Sin embargo, la mínima tasa de aciertos no se obtiene cuando $r = 0$, sino cuando $r \leq -10$. Mientras más mayor sea γ , mayor es la caída de las tasas de acierto si $r < 0$, y cuando $\gamma > 1$ las tasas de acierto se vuelven estables, aunque bajas, en la medida que $r \geq 0$. En resumen, las mejores tasas de acierto se obtienen cuando γ es un valor pequeño (cercano a 0,001 o menos) y r se aleja de 0 (positiva o negativamente).

Finalmente, el cálculo del valor óptimo de C se estableció entre los siguientes límites

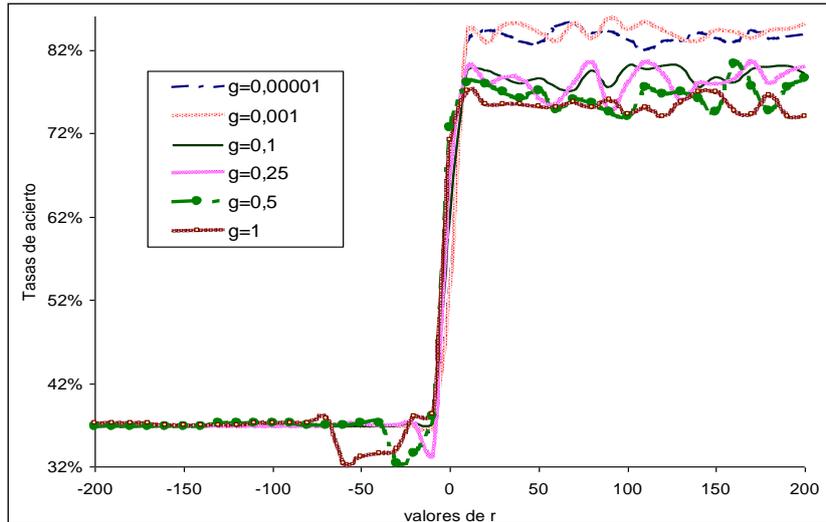
$$\begin{array}{l} \eta = -10 \\ \phi = 10 \\ \delta = 1 \end{array} \quad \implies \quad C = [0,000976563 ; 128],$$

obteniéndose el máximo nivel de aciertos (en promedio) de 85,20% cuando el costo tenía, en promedio, un valor $c = 1,32$.

D.4) Kernel Polinomial de grado 4

Para el Kernel polinomial de cuarto grado en la medida que $r < 0$, el nivel de aciertos es aproximadamente la mitad del acierto máximo (a distintos valores de gamma). Los mayores niveles de aciertos se pueden obtener con $r > 0$, manteniéndose en un pequeño rango de variación (con variaciones de +/- 1%) para cada valor de gamma. De los valores de gamma el mayor porcentaje de aciertos se logra con gamma muy pequeño ($0 < \gamma \leq 0,001$) y $r > 0$.

Figura A 43. Tasas de acierto del kernel polinomial de grado 4 ante cambios de r.



Finalmente, el cálculo del valor óptimo de C se estableció entre los siguientes límites

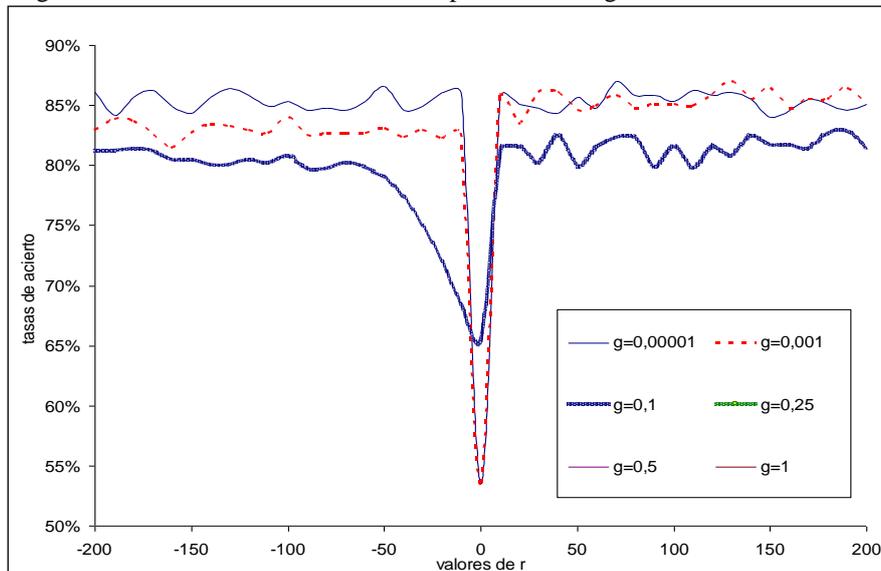
$$\begin{array}{rcl}
 \eta = & -10 & \\
 \phi = & 10 & \implies C = [0,000976563 ; 128], \\
 \delta = & 1 &
 \end{array}$$

obteniéndose el máximo nivel de aciertos (en promedio) de 85,0% cuando el costo tenía, en promedio, un valor $C = 28,15$.

D.5) Kernel Polinomial de grado 5

Las formas de las distribuciones de tasas de acierto en el kernel polinomial de quinto grado son similares a las de tercer grado. En la medida que $r \rightarrow 0$ el nivel de aciertos disminuye a casi el 50%. La magnitud de esta diferencia y el rango del valor de r que permite maximizar el grado de aciertos depende del valor que tome gamma (ver Figura A 44).

Figura A 44. Tasas de acierto del kernel polinomial de grado 5 ante cambios de r.



La distribución de aciertos es relativamente isométrica respecto de r cuando γ tiene un valor muy pequeño. En la figura esto se aprecia cuando $0 < \gamma \leq 0,001$. Cuando $\gamma = 0,00001$ y $r =]-10, 10[$, el nivel de aciertos baja significativamente (hasta aciertos del 55%). En la medida que γ aumenta levemente, el rango en que los valores de r minimizan los aciertos disminuye. En la figura se puede observar que para $\gamma = 0,001$, el rango de r con menores tasas de aciertos se encuentra en $]-10, 10[$, pero es menos isométrica a aquella distribución con $\gamma = 0,00001$, debido a que con $r < 0$ las tasas de acierto son en promedio un 2,5% menores. La isometría en las distribuciones de aciertos desaparece en la medida que γ va aumentando.

Finalmente, el cálculo del valor óptimo de C se estableció entre los siguientes límites

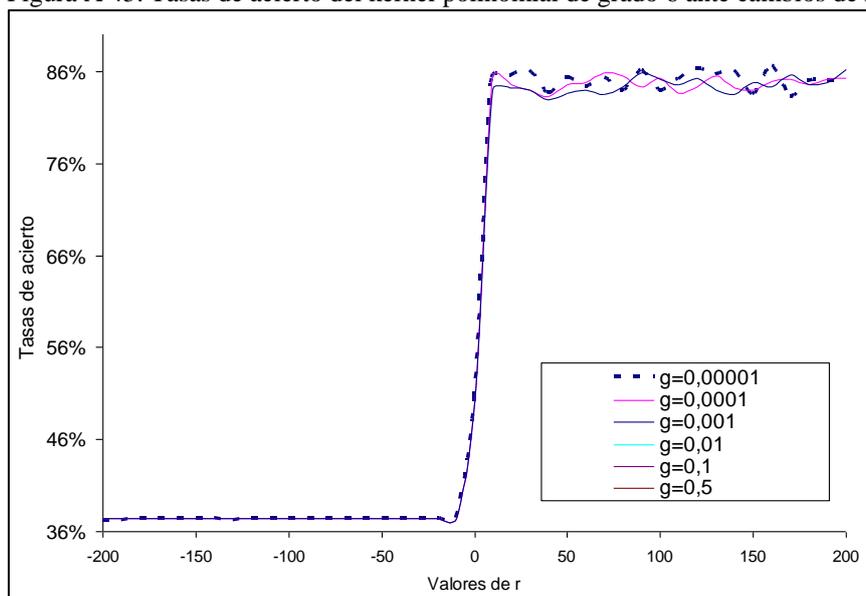
$$\begin{array}{l} \eta = -10 \\ \phi = 10 \\ \delta = 1 \end{array} \quad \implies \quad C = [0,000976563 ; 128],$$

obteniéndose el máximo nivel de aciertos (en promedio) de 85,33% cuando el costo tenía, en promedio, un valor $c = 11,96$.

D.6) Kernel Polinomial de grado 6

Para el kernel polinomial de sexto grado, sin importar el valor de gamma, las menores tasas de acierto se obtienen cuando $r < 0$, reduciéndose a menos de la mitad de los aciertos máximos. Por tanto, los mayores niveles de aciertos se obtienen con $r > 0$, manteniéndose en un rango pequeño de variación (con variaciones de +/- 1%), para cualquier valor de gamma (ver Figura A 45).

Figura A 45. Tasas de acierto del kernel polinomial de grado 6 ante cambios de r .



Finalmente, el cálculo del valor óptimo de C se estableció entre los siguientes límites

$$\begin{array}{lcl} \eta = & -10 & \\ \phi = & 10 & \implies C = [0,000976563 ; 128], \\ \delta = & 1 & \end{array}$$

obteniéndose el máximo nivel de aciertos (en promedio) de 84,93% cuando el costo tenía, en promedio, un valor $c = 1,21$.

E.2. Calibración de parámetros en la fase 2

El procedimiento de evaluación de conjuntos con mejor bondad de la réplica de rating fue homólogo para la tarea de biclasificación en la fase 1 como la tarea de multclasificación en la fase 2. Sin embargo, en la fase 2 se ha incluido nuevos parámetros de medición de la bondad (RMSE, tasas de error en la clasificación o réplica total y desagregada por niveles, indicadores de simetría del error total y por niveles). Esto ha causado que el análisis sea más extenso de exponer y más complejo de analizar.

En la fase 2 este procedimiento de evaluación de conjuntos de parámetros óptimos incluyó la salida automatizada de datos (en el software R) con los indicadores que permitían evaluar la bondad de las réplicas. Los archivos generados con estos procesos automatizados contenían los valores de los parámetros y los indicadores de medición de la bondad, es decir, RMSE, tasas de acierto, errores de sobrestimación y de subestimación en diferentes niveles (que en la Figura A 46 aparecen con los nombres de campo *sobre_1*, *sobre_2*, *sobre_3*, *sobre_4*, *sub_1*, *sub_2*, *sub_3*, *sub_4*), el tiempo que demoró el sistema automático en realizar el aprendizaje, los grados de simetría obtenidos en la réplica a nivel total (*Sim T*) y en los cuatro niveles de desagregación (*Sim N1*, *Sim N2*, *Sim N3* y *Sim N4*). La manipulación final de los datos para realizar más fácilmente la calibración y elección de los parámetros óptimos se ha usado MS Excel 2007. Como se puede observar en Figura A 46, en los principales indicadores de bondad (acierto y simetría de los errores) se coloreaban las celdas para comprender más adecuadamente las características que tenían los conjuntos de indicadores, de acuerdo a los parámetros elegidos. Para encontrar más fácilmente los conjuntos de parámetros óptimos se han coloreado de acuerdo a los niveles de eficiencia. La versión impresa de esta tesis carece de colores, pero se pueden apreciar las tonalidades de grises para identificar los grados de las tasas de acierto y simetría

Figura A 46. Captura de pantalla de archivo con indicadores de bondad de predicción y los parámetros de un kernel polinomial de grado 1 en la fase de entrenamiento y validación cruzada 10-cv, usando M2

coef0	cost	degree	gamma	kernel	modelo	RMSE	acierto	sobre	sub	sobre_1	sobre_2	sobre_3	sobre_4	sub_1	sub_2	sub_3	sub_4	tiempo	Sim T	Sim N1	Sim N2	Sim N3	Sim N4
-1,00E-04	0,001	1	0,001	polynomial	2	1,342444	25,4068	47,2502	23,343	24,9458	16,6706	3,88175	1,75203	18,8415	4,5015	0	0	1,12	2,02	1,32	3,70	-	-
-1,00E-04	0,01	1	0,001	polynomial	2	1,3250792	25,0808	47,8361	23,0831	25,421	17,3391	3,37952	1,69642	18,6749	4,4082	0	0	1,18	2,07	1,36	3,93	-	-
-1,00E-04	0,1	1	0,001	polynomial	2	1,2452675	25,2951	48,057	22,6479	26,0925	17,4084	3,56445	0,99164	18,2389	4,40896	0	0	1,11	2,12	1,43	3,95	-	-
-1,00E-04	1	1	0,001	polynomial	2	0,9157742	42,31298	28,4993	29,1878	23,4404	10,0244	1,00643	0	25,2544	3,93333	0	0	1,1	0,98	0,93	1,03	-	-
-1,00E-04	10	1	0,001	polynomial	2	0,8201517	49,66882	25,3376	24,9937	21,5026	3,51753	0,31745	0	22,9703	2,02331	0	0	1,15	1,01	0,94	1,74	-	-
-1,00E-05	0,001	1	0,001	polynomial	2	1,337457	29,89773	47,49	22,8123	25,0232	16,9428	3,78861	1,73532	18,2541	4,35824	0	0	1,19	2,10	1,37	3,89	-	-
-1,00E-05	0,01	1	0,001	polynomial	2	1,3464452	29,48028	47,5367	22,9831	24,4993	17,4255	3,59785	2,01397	18,5395	4,44361	0	0	1,11	2,07	1,32	3,92	-	-
-1,00E-05	0,1	1	0,001	polynomial	2	1,258002	29,39605	47,4611	23,1429	25,5345	17,0363	3,48733	1,403	18,4929	4,65	0	0	1,16	2,05	1,38	3,66	-	-
-1,00E-05	1	1	0,001	polynomial	2	0,9216008	42,70943	30,9953	26,2952	24,9196	5,1848	0,8909	0	22,8798	3,41537	0	0	1,1	1,18	1,09	1,52	-	-
-1,00E-05	10	1	0,001	polynomial	2	0,852413	49,43807	25,7092	24,8527	20,8937	4,21359	0,60193	0	22,7393	2,11337	0	0	1,24	1,03	0,92	1,99	-	-
0	0,001	1	0,001	polynomial	2	1,3180895	30,21853	47,2295	22,552	25,4441	16,6215	3,61752	1,54636	18,2352	4,31679	0	0	1,13	2,09	1,40	3,85	-	-
0	0,01	1	0,001	polynomial	2	1,324141	29,78973	47,5817	22,6286	25,0331	17,1349	3,8497	1,56397	18,3053	4,32334	0	0	1,27	2,10	1,37	3,96	-	-
0	0,1	1	0,001	polynomial	2	1,2549015	29,35522	47,1545	23,4903	24,8372	17,7059	3,37078	1,24063	18,919	4,57137	0	0	1,14	2,01	1,31	3,87	-	-
0	1	1	0,001	polynomial	2	0,9250241	41,52172	31,3996	27,0787	25,323	5,07485	1,00178	0	24,034	3,04462	0	0	1,18	1,16	1,05	1,67	-	-
0	10	1	0,001	polynomial	2	0,841999	47,86304	25,6327	26,5043	21,2775	3,97987	0,37527	0	24,4809	2,02347	0	0	1,12	0,97	0,87	1,97	-	-
1,00E-05	0,001	1	0,001	polynomial	2	1,3374104	29,099	47,4635	23,4375	25,4852	16,5705	3,52023	1,88749	19,1142	4,3233	0	0	1,17	2,03	1,33	3,83	-	-
1,00E-05	0,01	1	0,001	polynomial	2	1,3417082	29,82378	47,19	22,9662	24,2172	17,2727	3,88825	1,81186	18,5028	4,48344	0	0	1,17	2,05	1,31	3,85	-	-
1,00E-05	0,1	1	0,001	polynomial	2	1,2475866	29,25306	47,3734	23,3735	25,72	16,9199	3,64016	1,09335	18,8402	4,53332	0	0	1,11	2,03	1,37	3,73	-	-
1,00E-05	1	1	0,001	polynomial	2	0,9438143	41,52824	31,9858	26,4859	25,6868	5,06548	1,23347	0	23,0475	3,43847	0	0	1,14	1,21	1,11	1,47	-	-
1,00E-05	10	1	0,001	polynomial	2	0,8286232	48,59982	24,9602	26,44	21,0534	3,56008	0,34671	0	24,4533	1,98673	0	0	1,12	0,94	0,86	1,79	-	-
1,00E-04	0,001	1	0,001	polynomial	2	1,3420476	30,05338	46,86	23,0866	24,4487	16,8621	3,73995	1,80925	18,5096	4,57705	0	0	1,12	2,03	1,32	3,68	-	-
1,00E-04	0,01	1	0,001	polynomial	2	1,3417813	28,98459	48,0669	22,9466	25,4135	16,92	3,78679	1,94671	18,7066	4,24003	0	0	1,34	2,09	1,36	3,99	-	-
1,00E-04	0,1	1	0,001	polynomial	2	1,2624669	29,70021	47,6148	22,685	24,8213	17,6327	4,15289	1,00787	18,2232	4,46186	0	0	1,1	2,10	1,36	3,95	-	-
1,00E-04	1	1	0,001	polynomial	2	0,9109814	42,60771	30,7738	26,6185	25,3723	4,23534	1,16622	0	22,9996	3,61891	0	0	1,09	1,16	1,10	1,17	-	-
1,00E-04	10	1	0,001	polynomial	2	0,8526499	48,41944	25,7114	25,8691	20,5351	4,80761	0,36876	0	24,2487	1,62041	0	0	1,16	0,99	0,85	2,97	-	-
-1,00E-04	0,001	1	0,01	polynomial	2	1,3186442	30,17426	46,4804	23,3453	24,9208	16,2129	3,67915	1,66758	18,8589	4,48645	0	0	1,21	1,99	1,32	3,61	-	-
-1,00E-04	0,01	1	0,01	polynomial	2	1,2553978	29,87036	46,9755	23,1542	25,0901	17,0517	3,43169	1,40192	18,6408	4,51339	0	0	1,16	2,03	1,35	3,78	-	-
-1,00E-04	0,1	1	0,01	polynomial	2	0,9510208	41,2683	31,8921	26,8397	25,8584	4,62809	1,4056	0	23,2726	3,5671	0	0	1,11	1,19	1,11	1,30	-	-
-1,00E-04	1	1	0,01	polynomial	2	0,8353479	48,88289	25,0808	26,0363	21,0305	3,78116	0,26912	0	23,7758	2,2605	0	0	1,11	0,96	0,88	1,67	-	-
-1,00E-04	10	1	0,01	polynomial	2	0,8417215	51,05041	23,8687	25,0909	19,8365	3,57361	0,45858	0	23,4895	1,59136	0	0	1,41	0,95	0,84	2,25	-	-
-1,00E-05	0,001	1	0,01	polynomial	2	1,3355199	29,97078	47,0415	22,9878	24,187	17,2442	3,90447	1,70572	18,6034	4,38436	0	0	1,13	2,05	1,30	3,93	-	-
-1,00E-05	0,01	1	0,01	polynomial	2	1,2584607	28,98222	48,1221	22,8957	25,63	17,2797	4,0544	1,15804	18,5456	4,3501	0	0	1,1	2,10	1,38	3,97	-	-
-1,00E-05	0,1	1	0,01	polynomial	2	0,9287166	41,2467	32,1208	26,6326	26,0411	5,18394	0,89576	0	22,9958	3,63675	0	0	1,08	1,21	1,13	1,43	-	-
-1,00E-05	1	1	0,01	polynomial	2	0,8438494	48,75944	25,8789	25,3617	21,5124	3,88864	0,47785	0	22,9328	2,42881	0	0	1,16	1,02	0,94	1,60	-	-
-1,00E-05	10	1	0,01	polynomial	2	0,830291	49,40477	24,5423	26,053	20,5855	3,60915	0,34759	0	23,9676	2,08535	0	0	1,14	0,94	0,86	1,73	-	-
0	0,001	1	0,01	polynomial	2	1,3438558	29,20664	47,002	23,7913	24,8249	16,4508	3,70984	2,01648	19,2482	4,54316	0	0	1,11	1,98	1,29	3,62	-	-
0	0,01	1	0,01	polynomial	2	1,2455359	28,98948	48,5049	22,5056	26,6239	17,1912	3,56047	1,12936	17,9753	4,53036	0	0	1,19	2,16	1,48	3,79	-	-
0	0,1	1	0,01	polynomial	2	0,9189733	42,05772	30,5466	27,3957	24,9768	4,66581	0,90392	0	23,7669	3,62891	0	0	1,18	1,12	1,05	1,29	-	-
0	1	1	0,01	polynomial	2	0,8447746	46,58574	27,0568	26,3575	22,8549	3,86494	0,33695	0	24,472	1,88554	0	0	1,1	1,03	0,93	2,05	-	-
0	10	1	0,01	polynomial	2	0,8480358	47,81943	25,0532	27,1274	20,9042	3,93622	0,21281	0	25,146	1,98134	0	0	1,45	0,92	0,83	1,99	-	-
1,00E-05	0,001	1	0,01	polynomial	2	1,3320885	28,93331	47,8857	23,181	25,4735	16,9782	3,64472	1,78936	18,8999	4,2811	0	0	1,15	2,07	1,35	3,97	-	-

Debido a la extensión de la cantidad de datos generados y al bajo nivel de interés que tendría observarlos, en esta tesis no se exponen las salidas de todos los archivos que contienen los parámetros. Se ha optado por entregar un resumen de los conjuntos de parámetros más relevantes (ver Tabla 42). A continuación sólo se exponen algunas tablas más representativas de la búsqueda de la calibración adecuada de los SVR para aumentar al máximo posible los niveles de acierto.

Figura A 47. Captura de pantalla de indicadores de bondad de predicción y parámetros óptimos de un kernel lineal en la fase de entrenamiento y validación cruzada 10-cv, repetida 10 oportunidades, usando M2

cost	kernel	modelo	RMSE	acierto	sobre	sub	sobre_1	sobre_2	sobre_3	sobre_4	sub_1	sub_2	sub_3	sub_4	tiempo	Sim T	Sim N1	Sim N2	Sim N3	Sim N4
10	linear	2	0,834283404	50,1997	23,8349	25,9654	19,7071	3,4621	0,6658	0	24,2344	1,731	0	0	5,1	0,92	0,81	2,00	-	-
10	linear	2	0,819266709	47,878	25,3316	26,7905	21,7507	3,3156	0,2653	0	24,8011	1,9894	0	0	4,6	0,95	0,88	1,67	-	-
10	linear	2	0,829664699	48,8064	24,5358	26,6578	20,9549	3,3156	0,2653	0	24,8011	1,8568	0	0	4,4	0,92	0,84	1,79	-	-
10	linear	2	0,834495511	48,6737	24,9337	26,3926	21,3528	3,3156	0,2653	0	24,6684	1,7241	0	0	4,6	0,94	0,87	1,92	-	-
10	linear	2	0,838388335	49,2021	24,2021	26,5957	20,3457	3,4574	0,3989	0	24,6011	1,9947	0	0	4,5	0,91	0,83	1,73	-	-

E.3. Resultados finales de réplica con SVR (fase 2)

Tabla A 73. Diferencias entre las tasas de acierto de cada una de las técnicas y kernels usados

Diferencias entre las tasas de acierto para M1 en entrenamiento

	% acierto	Lineal	Polinomial G1	Polinomial G2	Radial	Sigmoide	Anál.Discrim.	Regr.Logíst.
Lineal	60,9804	0,0000	0,3417	23,4474	26,5486	0,1585	-7,7255	-2,9506
Polinomial G1	61,3221	-0,3417	0,0000	23,1057	26,2069	-0,1832	-8,0671	-3,2923
Polinomial G2	84,4278	-23,4474	-23,1057	0,0000	3,1012	-23,2889	-31,1728	-26,3980
Radial	87,5289	-26,5486	-26,2069	-3,1012	0,0000	-26,3901	-34,2740	-29,4992
Sigmoide	61,1389	-0,1585	0,1832	23,2889	26,3901	0,0000	-7,8839	-3,1091
Anál.Discrim.	53,2549	7,7255	8,0671	31,1728	34,2740	7,8839	0,0000	4,7748
Regr.Logíst.	58,0297	2,9506	3,2923	26,3980	29,4992	3,1091	-4,7748	0,0000

Diferencias entre las tasas de acierto para M1 en validación

	% acierto	Lineal	Polinomial G1	Polinomial G2	Radial	Sigmoide	Anál.Discrim.	Regr.Logíst.
Lineal	59,0782	0,0000	0,5654	-4,0050	2,4399	1,1128	-11,2611	-5,7396
Polinomial G1	59,6435	-0,5654	0,0000	-4,5704	1,8745	0,5474	-11,8264	-6,3049
Polinomial G2	55,0731	4,0050	4,5704	0,0000	6,4449	5,1178	-7,2561	-1,7345
Radial	61,5180	-2,4399	-1,8745	-6,4449	0,0000	-1,3271	-13,7010	-8,1794
Sigmoide	60,1909	-1,1128	-0,5474	-5,1178	1,3271	0,0000	-12,3738	-6,8523
Anál.Discrim.	47,8171	11,2611	11,8264	7,2561	13,7010	12,3738	0,0000	5,5215
Regr.Logíst.	53,3386	5,7396	6,3049	1,7345	8,1794	6,8523	-5,5215	0,0000

Diferencias entre las tasas de acierto para M2 en entrenamiento

	% acierto	Lineal	Polinomial G1	Polinomial G2	Radial	Sigmoide	Anál.Discrim.	Regr.Logíst.
Lineal	48,7620	0,0000	-0,7597	-7,9128	26,9999	-1,9732	1,1279	4,1818
Polinomial G1	48,0023	0,7597	0,0000	-7,1531	27,7596	-1,2136	1,8876	4,9415
Polinomial G2	40,8492	7,9128	7,1531	0,0000	34,9127	5,9396	9,0407	12,0946
Radial	75,7619	-26,9999	-27,7596	-34,9127	0,0000	-28,9731	-25,8720	-22,8181
Sigmoide	46,7887	1,9732	1,2136	-5,9396	28,9731	0,0000	3,1011	6,1551
Anál.Discrim.	49,8898	-1,1279	-1,8876	-9,0407	25,8720	-3,1011	0,0000	3,0540
Regr.Logíst.	52,9438	-4,1818	-4,9415	-12,0946	22,8181	-6,1551	-3,0540	0,0000

Diferencias entre las tasas de acierto para M2 en validación

	% acierto	Lineal	Polinomial G1	Polinomial G2	Radial	Sigmoide	Anál.Discrim.	Regr.Logíst.
Lineal	48,0978	0,0000	0,8449	-10,2292	11,1974	1,5968	-0,3552	4,2512
Polinomial G1	48,9427	-0,8449	0,0000	-11,0741	10,3525	0,7520	-1,2001	3,4064
Polinomial G2	37,8686	10,2292	11,0741	0,0000	21,4267	11,8261	9,8740	14,4805
Radial	59,2953	-11,1974	-10,3525	-21,4267	0,0000	-9,6006	-11,5527	-6,9462
Sigmoide	49,6947	-1,5968	-0,7520	-11,8261	9,6006	0,0000	-1,9521	2,6544
Anál.Discrim.	47,7426	0,3552	1,2001	-9,8740	11,5527	1,9521	0,0000	4,6065
Regr.Logíst.	52,3491	-4,2512	-3,4064	-14,4805	6,9462	-2,6544	-4,6065	0,0000