

**LA PREDICCIÓN DEL FRACASO EMPRESARIAL MEDIANTE MODELOS
BASADOS EN LA TÉCNICA BOOSTED REGRESSION TREES (BRT)**

José Pozuelo Campillo

Departament de Comptabilitat

Universitat de València - Facultat d'Economia

Pedro Carmona Ibáñez

Departament de Comptabilitat

Universitat de València

Julián Martínez Vargas

Departament de Comptabilitat

Universitat de València

Área temática: A) Información Financiera y Normalización Contable.

Palabras clave: Fracaso empresarial, árboles de regresión potenciados

LA PREDICCIÓN DEL FRACASO EMPRESARIAL MEDIANTE MODELOS BASADOS EN LA TÉCNICA BOOSTED REGRESSION TREES (BRT)

Resumen

La crisis económica que hemos sufrido durante varios años ha supuesto un notable incremento de los fracasos empresariales, paralelo a la renovación del interés de los investigadores por la cuestión.

En este trabajo pretendemos el desarrollo de modelos de predicción de fracaso empresarial incorporando la metodología “Boosted Regression Trees” (BRT) extraída del Machine Learning que, aunque ya se viene utilizando en otro tipo de estudios mostrando una gran eficiencia, todavía no se ha prodigado en esta línea de investigación.

Para ello aplicaremos la técnica del BRT sobre unas muestras de datos financieros de 2.083 empresas españolas y evaluaremos, en función de los resultados obtenidos, si es apropiada para la predicción del fracaso empresarial.

1.- INTRODUCCIÓN

La crisis económica y financiera que hemos sufrido durante varios años y de la que todavía no estamos en condiciones de poder asegurar que forme parte del pasado, ha supuesto un notable incremento de los fracasos empresariales

En este trabajo pretendemos el desarrollo de modelos de predicción de fracaso empresarial incorporando una metodología extraída del Machine Learning “Boosted Regression Trees” (BRT) que, aunque ya se viene utilizando en otro tipo de estudios mostrando gran eficiencia, todavía no se ha prologado en esta línea de investigación.

Para ello aplicaremos la técnica sobre unas muestras de datos financieros de 2.083 empresas españolas e intentaremos evaluar, en función de los resultados obtenidos, si es apropiada para la predicción del fracaso empresarial.

Para lograr el objetivo propuesto cubriremos las siguientes etapas:

1. Definición de fracaso empresarial utilizada en el estudio.
2. Confección de una base de datos integrada por empresas cuyos registros cumplan las especificaciones exigidas por los objetivos del trabajo.
3. Selección y definición de las variables explicativas.
4. Aplicación de la técnica BRT sobre una muestra de entrenamiento para después medir la capacidad predictiva del algoritmo sobre una muestra independiente de validación.

En nuestro país la metodología boosting la propone y justifica Alfaro Cortés (2006) como herramienta para la previsión del fracaso empresarial por minimizar los errores de clasificación entre empresas sanas y fracasadas. También destacamos el reciente estudio de Momparler et al. (2016) centrado en entidades bancarias de la Eurozona y cuyos resultados resultan muy satisfactorios en cuanto al alto poder de predicción del modelo (un 98,67% de acierto).

3.- DESARROLLO METODOLÓGICO

3.1- Definición de fracaso empresarial utilizada en el estudio.

La delimitación del concepto de fracaso empresarial es fundamental para la selección de las empresas que formarán las diferentes muestras sobre las que se realizará el estudio. Se ha optado por una definición de fracaso que permita distinguir con claridad las empresas sanas de las que no lo son. De esta manera se ha equiparado el fracaso a la calificaciones jurídica de situación concursal, según Ley Concursal 22/2003, de modo que una empresa se considerará fracasada si ha presentado un expediente concursal y sana en el caso contrario. Aunque este criterio, de marcado carácter jurídico, presenta algunos inconvenientes, como la reducción considerable de los tamaños muestrales, entendemos que son superados por las ventajas de objetividad y fijación de la fecha del fracaso que aporta en el proceso de selección de las empresas que integrarán las distintas muestras.

3.2.- Selección de la muestra de empresas

En el proceso de selección y obtención de las diferentes muestras de empresas se ha recurrido a la base de datos financieros *SABI* (Sistema de Análisis de Balances Ibéricos), cuyo uso ha sido cedido a la Universitat de València por la empresa *INFORMA S.A.*

Para seleccionar las empresas de la muestra de estimación se han considerado aquellas firmas españolas que presentaron expediente de situación concursal en el año 2013. Esta condición la cumplían 9.937 empresas pertenecientes a prácticamente todos los sectores productivos.

Sobre esta población se realizaron dos filtrados. Uno para que la muestra guardase un número proporcional al índice de fracaso del sector en que operaban y otro, por el que se descartaron aquellas empresas de reciente creación (hasta tres años) y las que no contenían datos contables completos de al menos tres ejercicios anteriores a la fecha del fracaso. También se ha prescindido de las empresas de seguros y financieras, Tras estos procesos de selección y filtrado, el número de firmas se redujo a 1.118 empresas concursadas que son las que definitivamente se integrarán en la muestra de estimación.

Para completar la muestra de estimación y poder aplicar ciertas herramientas estadísticas de clasificación, se recurrió a la técnica del emparejamiento consistente en asociar empresas quebradas con sanas de las mismas características elegidas

aleatoriamente entre aquellas de un tamaño similar, en nuestro caso medido en función del volumen de activo, y que operase en el mismo sector económico establecido por el C.N.A.E (rev). de 2009 (Clasificación Nacional de Actividades Económicas) a nivel de cuatro dígitos y cuando no ha sido posible se ha descendido a tres dígitos. También se exigió que existiese una correspondencia temporal de sus estados contables con los ejercicios obtenidos para las empresas quebradas. Con este proceso se incorporaron 965 empresas sanas, quedando la muestra de estimación balanceada finalmente compuesta por 2.083 empresas, es decir, compuesta aproximadamente de un número similar de empresas sanas y concursadas.

A continuación, se plasmaron las observaciones de los tres años previos al momento del fracaso.

Como último paso, los resultados obtenidos y, en definitiva, la capacidad predictiva del modelo así como su grado de generalización, se deberán contrastar mediante una muestra de validación. En este sentido, de la muestra total de 2.083 se ha reservado un 25% de observaciones como muestra de validación, en la que se comprobará la capacidad predictiva y de generalización del modelo obtenido.

3.3.-Selección y definición de las variables explicativas

Uno de los aspectos más relevantes en la elaboración de modelos de predicción de fracaso empresarial es determinar las variables independientes que lo integrarán, en nuestro caso ratios económico-financieros. Ante la ausencia de una teoría general que guíe el proceso de selección de ratios, lo que constituye una fuerte limitación a la hora de modelizar el fracaso empresarial¹. nos basaremos en:

1. Ratios tradicionales en la literatura sobre análisis contable.
2. Frecuencia de aparición en estudios anteriores.
3. Facilidad para ser calculados y definidos en función de la información contable disponible.

En principio consideramos una amplia lista de ratios contenidos en diferentes categorías. Los solapamientos de información y problemas estadísticos, que necesariamente han de producirse, serán depurados con las técnicas estadísticas apropiadas eliminando aquellas que apenas aporten información adicional. Dado que

¹ Un estudio interesante que aporta una guía para la incorporación de ratios basados en un modelo económico-financiero de solvencia empresarial lo encontramos en Dieguez et Al. (2006).

nuestro objetivo es la formulación de modelos de predicción de fracaso empresarial incidiremos en aquellas variables que, en principio, informen sobre los aspectos de la solvencia y rentabilidad de la firma, sin olvidar la influencia del endeudamiento. A estas categorías añadiremos las de rotación, actividad y estructura de activo. Describimos a continuación las categorías en las que incluiremos las diferentes ratios:

1. Rentabilidad (REN)

Existe prácticamente unanimidad en la doctrina de análisis contable en considerar la rentabilidad económica como indicador de la eficacia de la empresa en la utilización de sus inversiones y la rentabilidad financiera como indicador de la capacidad de la empresa para crear riqueza a favor de sus propietarios. Haremos especial hincapié en la rentabilidad asociada a la explotación, por entender que es en este tramo donde se aprecia con claridad si una empresa es o no rentable. Dentro de la categoría de rentabilidad hemos considerado unas ratios de naturaleza mixta integradas por las magnitudes de beneficio en sus distintos niveles y de endeudamiento. También, en la categoría de rentabilidad se han integrado algunas ratios planteadas con el Cash-Flow en su acepción tradicional de recursos generados.

2. Estructura financiera o Endeudamiento (EF)

Con estos indicadores se podrá establecer el grado de dependencia de los acreedores de la empresa en función de la fuente de recursos financieros que utiliza.

3. Actividad (ACT)

Con los regresores de actividad se trata de ponderar cada concepto de gasto respecto a la actividad realizada.

4. Rotación (ROT)

Con ellas se pretenderá determinar el grado de eficiencia de las operaciones más significativas de la empresa, fundamentalmente aquellas vinculadas con la actividad principal.

5. Solvencia a corto plazo (SOLV)

Las ratios de solvencia a corto plazo o liquidez, ligadas estrechamente a la situación de equilibrio financiero, indican la capacidad que la empresa tiene para atender sus deudas a corto plazo.

6. Solvencia a largo plazo (SOLV LP)

Con estas ratios se pretende determinar la capacidad de la empresa para afrontar sus deudas a largo plazo. Estas medidas centran su atención en la estructura financiera y operativa de la empresa contemplada desde el largo plazo.

7. Estructura económica (CF)

Las ratios de esta categoría relacionan elementos y masas patrimoniales de activo mostrando la estructura de las inversiones ponderando cada elemento o partida respecto al total de ellas.

En nuestro estudio partiremos de la información contenida en los estados financieros de las sociedades transformándola en ratios, lo que nos permitirá establecer con rigor su situación económico-financiera y realizar comparaciones entre las distintas empresas y diferentes periodos económicos. Por razones de tipo operativo no hemos considerado información de naturaleza cualitativa.

La lista de las ratios consideradas inicialmente y separados por categorías la mostramos en las siguientes tablas:

Tabla 1. Variables explicativas

RENTABILIDAD		
CLAVE	RATIO	
REN 1	RESULTADO DEL EJERCICIO/ACTIVO TOTAL	R/AT
REN 2	RESULTADO DEL EJERCICIO/FONDOS PROPIOS	R/FP
REN 3	RESULTADO DEL EJERCICIO/PASIVO TOTAL	R/PT
REN 4	RESULTADO DEL EJERCICIO/VENTAS	R/V
REN 5	CASH FLOW RECURSOS GENERADOS/FONDOS PROPIOS	CF/FP
REN 6	CASH FLOW RECURSOS GENERADOS/ACTIVO TOTAL	CF/AT
REN 7	CASH FLOW RECURSOS GENERADOS/PASIVO TOTAL	CF/PT

ESTRUCTURA FINANCIERA		
CLAVE	RATIO	
EF 1	PASIVO TOTAL/FONDOS PROPIOS	PT/FP
EF 2	GASTOS FINANCIEROS/PASIVO TOTAL	GF/PT
EF 3	GASTOS FINANCIEROS/ VENTAS	GF/V

ACTIVIDAD		
CLAVE	RATIO	
ACT 1	VALOR AÑADIDO/VENTAS	VA/V
ACT 2	RESULTADO DEL EJERCICIO/VALOR AÑADIDO	R/VA

ROTACION		
CLAVE	RATIO	
ROT 1	VENTAS/ACTIVO TOTAL	V/AT

SOLVENCIA (Liquidez)		
CLAVE	RATIO	
SOLV 1	ACTIVO CORRIENTE /PASIVO CORRIENTE	AC/PC
SOLV 2	ACTIVO CORRIENTE - EXISTENCIAS/PASIVO CORRIENTE	AC-EX/PC
SOLV 3	DISPONIBLE/PASIVO CORRIENTE	D/PC

SOLVENCIA A LARGO PLAZO		
CLAVE	RATIO	
SOLV LP 1	RECURSOS GENERADOS ANTES DE IMPUESTOS/PASIVO TOTAL	RGAI/PT
SOLV LP 2	ACTIVO TOTAL NETO/PASIVO TOTAL	AT/PT

ESTRUCTURA ECONOMICA		
CLAVE	RATIO	
CF 1	ACTIVO CORRIENTE/ACTIVO TOTAL	AC/AT

Todas las partidas integrantes de los ratios han sido derivadas del Balance de Situación y cuenta de Pérdidas y Ganancias de las empresas que componen las diferentes muestras.

4.- ESTUDIO ESTADÍSTICO

4.1.- Metodología

En nuestro estudio hemos recurrido a diferentes ratios financieros del año 2013 con la finalidad de identificar los factores determinantes en la predicción del fracaso empresarial en España. Estamos pues ante un problema de clasificación que requiere la búsqueda de un modelo que sea capaz de clasificar a las empresas como sanas o en peligro de quiebra. Para alcanzar este objetivo se ha seguido un procedimiento relativamente nuevo, árboles de regresión potenciados (Boosted Regression Trees, BRT).

BRT es un tipo de técnica iterativa que persigue la minimización de los errores mediante la introducción de nuevos modelos que se basan en los errores de las iteraciones anteriores. En particular, se emplea con bastante éxito en el ámbito de los problemas relacionados con la clasificación. Entre los diferentes métodos que hacen uso del “boosting”, los más comunes son “AdaBoost”, “gradient boosting” y “stochastic gradient boosting”. Estos métodos emplean diferentes modelos que se van agregando,

el resultado de la agregación es un modelo final con una capacidad predictiva superior a la de los modelos utilizados individualmente (Chambers and Dinsmore, 2015).

De acuerdo con Kuhn y Johnson (2013), los algoritmos basados en “boosting” se desarrollaron en la última década del siglo XX cuando un conjunto de *clasificadores débiles* empezó a combinarse con la finalidad de producir un *clasificador de ensamble* que tuviera una ratio global de error de clasificación incorrecta muy inferior a la de los modelos tradicionales. “AdaBoost” supuso una implementación práctica que permitió reforzar un *clasificador débil* y convertirlo en un *clasificador robusto*. Posteriormente, el algoritmo de “AdaBoost” se fue generalizando para su uso en los problemas de clasificación y dio lugar al algoritmo “gradient boosting” de Friedman (2001). Posteriormente, Friedman introdujo en su algoritmo algunas características extraídas de las técnicas basadas en “bagging”, como el muestreo aleatorio para la formación de los modelos, lo cual supuso el desarrollo de un nuevo procedimiento que se denominó “stochastic gradient boosting”.

Los modelos basados en “boosting” son una herramienta práctica muy útil en los problemas de predicción, pues de un modo consistente proporcionan resultados más precisos en comparación con los modelos convencionales (Natekin and Knoll, 2013). “Boosting” permite incrementar la precisión de los modelos de predicción; toma como premisa fundamental el hecho de que resulta más sencillo desarrollar y promediar muchos modelos sencillos, que crear un único modelo de predicción que tenga una alta capacidad predictiva (Schapire, 2003). En nuestro estudio se ha aplicado el algoritmo “stochastic gradient boosting”, que de acuerdo con Kuhn and Johnson (2013) está considerado en la actualidad como el algoritmo de “boosting” más empleado. La estocasticidad mejora los resultados predictivos y reduce la varianza final del modelo, pues implica utilizar sólo un subconjunto aleatorio de los datos muestrales para ajustar cada uno de los árboles individuales de los modelos que integran el modelo final (Friedman 2002).

BRT crea múltiples copias de los datos de la muestra mediante la técnica “bootstrap”, de modo que ajusta un árbol de decisión diferente para cada copia y, entonces, mediante la combinación de todos estos árboles, desarrolla un único modelo de predicción. La creación de los árboles se realiza de forma secuencial y en cada iteración del algoritmo se ajusta el peso de las observaciones según la capacidad predictiva de la muestra. En “stochastic gradient boosting” la construcción de cada árbol de decisión depende mucho de los árboles previos que ya se hayan construido (Hastie et al. 2009).

En definitiva, la construcción de numerosos árboles de decisión en BRT ayuda a hacer frente al principal problema de los modelos basados en un único árbol, que es su escasa capacidad predictiva (Elith et al., 2008). El algoritmo basado en BRT va ajustando los árboles de decisión a los residuos del modelo y añade estos nuevos árboles dentro de la función del modelo con el fin de ir actualizando los residuos. Cada uno de estos árboles suele ser bastante pequeño, con muy pocos nodos terminales. El hecho de ajustar árboles muy pequeños a los residuos permite que de forma progresiva y lentamente mejore el modelo final (James et al. 2013). El modelo BRT resultante es en realidad una combinación lineal de muchos árboles de decisión (normalmente cientos o miles), que puede entenderse como un modelo de regresión donde cada término es un árbol de decisión individual (Elith et al., 2008).

La utilización de BRT supone necesariamente la especificación de tres parámetros importantes:

- La ratio de aprendizaje o parámetro de contracción, que generalmente es un número positivo pequeño, comprendido entre 0 y 1. Determina la rapidez con la que el algoritmo se va ajustando o la contribución de cada árbol de decisión al desarrollo del modelo. Ridgeway (2009) recomienda utilizar valores muy pequeños de la ratio de aprendizaje ($< 0,01$). Reduce el tamaño de los pasos del algoritmo hasta llegar al modelo final, penalizando la importancia de cada iteración. De acuerdo con Natekin and Knoll (2013), una ratio pequeña beneficia el proceso de aprendizaje pues es mucho mejor construir el modelo a partir de numerosos pasos cortos que a partir de unos pocos pasos muy largos. El inconveniente de utilizar una ratio muy pequeña es que lleva consigo la construcción de muchísimos árboles de decisión, lo que incrementa el tiempo que tarda el ordenador en encontrar el modelo más adecuado. El valor de este parámetro es inversamente proporcional al tiempo de uso de la CPU de un ordenador.
- La profundidad de los árboles de decisión o profundidad de las iteraciones. Es el número de nodos que tienen los árboles, los cuales controlan la complejidad de la estructura del modelo final.
- El número de árboles de decisión. El número óptimo de árboles en un modelo BRT se puede obtener a partir de los dos parámetros anteriores o bien haciendo uso de técnicas de validación cruzada. Es fundamental encontrar la cantidad más adecuada de árboles de decisión. En este sentido, James *et al.* (2013) señalan que un número demasiado elevado de árboles puede mejorar

drásticamente la precisión global del modelo en la muestra de entrenamiento, pero a costa de la pérdida de precisión global en la muestra de validación. En otras palabras, la utilización de un valor demasiado alto del número de árboles puede dar lugar a un mal modelo debido a un problema de sobreajuste.

En nuestro estudio, con la finalidad de pronosticar el fracaso empresarial en España, pretendemos construir un modelo de clasificación que sea capaz de predecir una variable de respuesta cualitativa, consistente en las empresas españolas que entraron en situación de concurso de acreedores durante el año 2013. Como acabamos de comentar, vamos a hacer uso de un modelo BRT, que calcule la probabilidad de que una empresa pueda entrar en una situación de concurso. A partir de sucesivos pasos, el algoritmo intentará encontrar el mejor modelo agregado de árboles de decisión simples que minimice una función de pérdida, aprendiendo de la relación existente entre la variable de respuesta y el conjunto de predictores, de modo que proporcione una buena clasificación entre las empresas en activo y las que están en situación de concurso. Tal y como ya hemos señalado con anterioridad, como predictores hemos considerado un conjunto de ratios contables y financieros de las empresas.

Como función de pérdida tomaremos el estadístico AUC² (área bajo la curva) que toma valores entre 0 y 1, aunque es a partir de 0,5 cuando indica que un modelo de clasificación es superior a una mera clasificación aleatoria de los hechos. Un valor de 1 significaría que el modelo es perfecto y clasificaría el 100% de los casos correctamente. Entendemos que este indicador de la capacidad predictiva de un modelo es superior al de la precisión global del modelo, tal y como defienden Cortes y Mohri (2004). Es uno de los indicadores más utilizados para valorar el rendimiento de un modelo y compararlo con otros. Se puede interpretar como la probabilidad de que un modelo de clasificación asigne a un evento de interés o caso positivo elegido aleatoriamente (empresa en situación de concurso) una ocurrencia mayor que la del evento sin interés o caso negativo (empresa activa). AUC se considera como una medida pura de la eficacia o capacidad predictiva de un modelo, pues es independiente del punto de corte que se utilice para clasificar las predicciones como positivas o negativas. De hecho, la medida de la precisión global del modelo o porcentaje de aciertos varía según el punto de corte que se emplee para clasificar las probabilidades de ocurrencia que predice el modelo como evento de interés o evento sin interés. Resumiendo, para comparar diferentes modelos de acuerdo con su capacidad predictiva nos basaremos en el estadístico AUC, pues responde a una medida que es independiente del punto de corte.

² Area Under Curve, en inglés

Todos los modelos se han construido utilizando la aplicación informática *R* (R Core Team, 2015) versión 3.2.3, así como los paquetes *gbm* versión 2.1.1 (Ridgeway, 2015) y *caret* versión 6.0-64 (Kuhn, 2016).

4.2.- Resultados

En primer lugar mostramos los principales estadísticos descriptivos de todas las variables utilizadas como predictores (Tabla 2). Disponemos de un total de 2.083 empresas, de las cuales 965 son empresas en activo y el resto en situación de concurso. Vamos a considerar la mediana como el estadístico de referencia para comparar los dos tipos de empresas ya que su cuantía no resulta influenciada por los valores extremos y, por tanto, es una de las medidas de centralidad de la distribución de las más aceptadas. En general, se aprecia que no hay grandes diferencias entre las empresas en activo y las empresas en concurso para el conjunto de variables consideradas. Destaca, sin embargo, la diferencia en la ratio de rotación (ROT1), que es considerablemente mayor para las empresas en activo (3,10) que para las que se encuentran en situación de concurso (0,73). Como se apreciará después, el modelo resultante considerará esta variable la más importante.

Selección de los parámetros óptimos del modelo

Anteriormente se ha especificado que el algoritmo BRT necesita la especificación de tres parámetros: la ratio de aprendizaje, la profundidad de los árboles de decisión y el número de árboles de decisión. Mediante la técnica de la validación cruzada intentaremos identificar el valor óptimo de estos parámetros. La Figura 1 muestra los resultados de este proceso y se aprecia en la misma que el modelo BRT alcanza una mayor precisión, de acuerdo con el estadístico AUC, con un total de 650 árboles de decisión, con una profundidad de los árboles de 5 nodos y con una ratio de aprendizaje de 0,1. El modelo proporciona, por medio de la validación cruzada, una estimación muy alta del estadístico AUC (0,98) en una hipotética muestra de comprobación o de validación, lo cual es indicativo de que el modelo tiene una capacidad predictiva muy elevada pues se aproxima a su valor máximo de 1.

Tabla 2. Resumen de los estadísticos descriptivos de los ratios de las empresas

Variable	media		d. s.		mediana		mínimo		máximo	
	NF	F	NF	F	NF	F	NF	F	NF	F
REN1	0,04	-0,29	0,13	0,93	0,03	-0,08	-1,61	-16,44	1,37	0,71
REN2	0,12	-1,75	1,26	42,10	0,07	0,01	-14,47	-1.343,02	31,16	204,46
REN3	-0,17	-0,27	8,42	2,26	0,03	-0,08	-255,93	-61,53	22,53	6,32
REN4	-0,01	-13,55	0,39	337,4	0,01	-0,15	-7,40	-11.230,86	0,73	171,98
REN5	0,17	-0,97	0,91	24,12	0,11	0,03	-14,15	-708,16	13,74	200,81
REN6	0,06	-0,26	0,14	0,90	0,05	-0,05	-1,61	-16,44	1,45	0,75
REN7	-0,11	-0,19	8,9	2,25	0,06	-0,06	-265,64	-56,56	36,13	36,40
EF1	3,40	10,15	25,83	372,12	0,89	0,31	-228,27	-3.938,15	450,51	11.393,09
EF2	0,01	0,03	0,47	0,30	0,01	0,03	-12,90	-4,95	1,93	1,80
EF3	0,01	5,19	0,02	71,47	0,01	0,04	0,01	0,01	0,45	1856,04
ACT1	0,13	-8,31	0,44	332,57	0,08	0,21	-6,32	-10.847,27	8,45	2.200,48
ACT2	-0,31	4,61	14,38	140,08	0,12	-0,02	-445,14	-71,14	15,23	4.669,32
ROT1	4,17	1,13	6,07	1,47	3,10	0,73	0,02	0,01	110,83	21,52
SOLV1	1,43	2,94	1,10	28,32	1,20	0,97	0,12	0,01	22,71	781,74
SOLV2	0,91	0,69	0,90	2,25	0,82	0,39	0,01	0,01	20,73	57,25
SOLV3	0,17	0,17	0,31	1,77	0,06	0,02	0,01	0,01	3,76	57,22
SOLVLP1	-0,11	-0,19	8,90	2,25	0,06	-0,06	-265,64	-56,56	36,13	36,4
SOLVLP2	0,72	1,01	54,17	21,13	1,54	1,04	-1.457,21	-369,02	317,15	416,97
CF1	0,76	0,55	0,19	0,3	0,81	0,59	0,03	0,01	1	1

NOTAS:

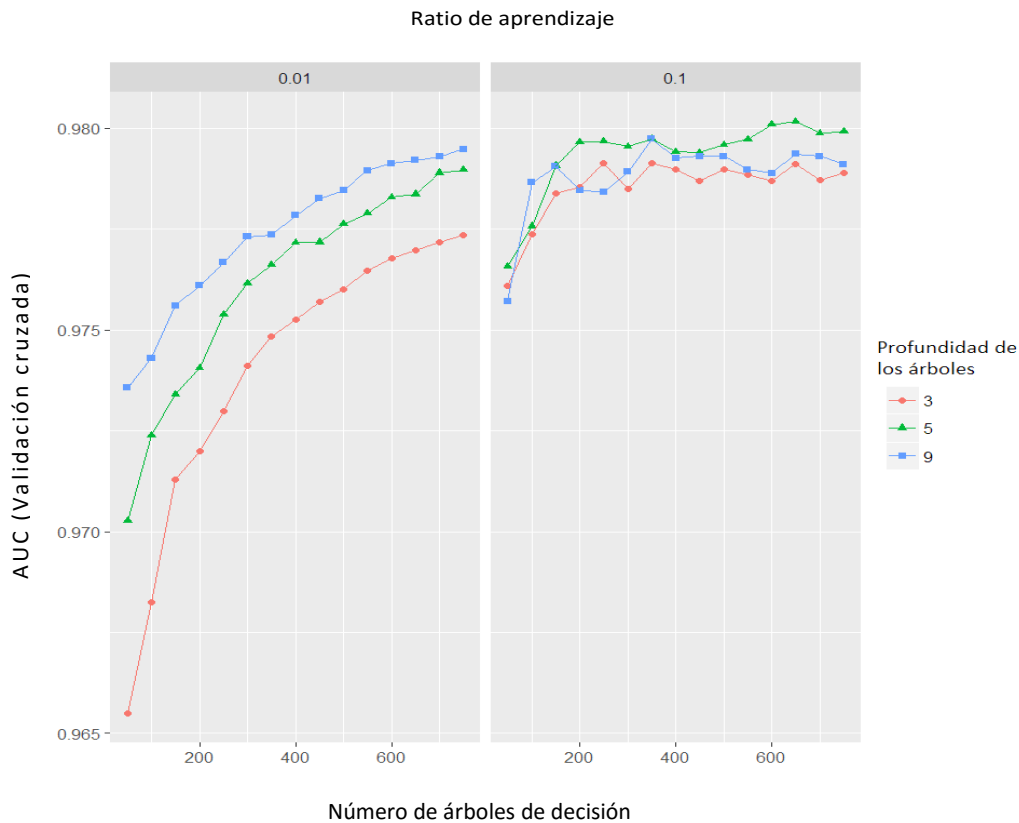
NF: Empresa no fracasada (965 observaciones)

F: Empresa fracasada (1.118 observaciones)

d. s.: desviación estándar

La descripción de las variables se encuentra en la Tabla 1


Figura 1. Obtención de los parámetros óptimos del modelo BRT



Importancia de las variables del modelo

La importancia de las variables del modelo BRT puede obtenerse midiendo la mejora que aporta cada una de los predictores en la búsqueda de la solución óptima del algoritmo. Esta medida se basa en el número de veces que una variable resulta seleccionada en la construcción de los árboles de decisión individuales. Para obtener la influencia de una variable en el modelo, ésta tiene que promediarse en el conjunto de los árboles de decisión individuales (Natekin and Knoll, 2013). La Figura 2 muestra la importancia de las variables del modelo BRT. Se aprecia que las variables que tienen un mayor peso son la ratio de ventas sobre el activo total (ROT1), la ratio de gastos financieros sobre ventas (EF3), la ratio del resultado del ejercicio sobre ventas (REN4) y la ratio del valor añadido sobre ventas (ACT1). Aunque el conjunto de árboles que conforman el modelo BRT es mucho más difícil de interpretar que un árbol de decisión individual, se puede obtener una valoración global de la importancia de cada predictor mediante el índice Gini, de modo cuanto más alto sea su valor mayor resulta la importancia relativa del predictor correspondiente.

Figura 2. Importancia de las variables del modelo BRT



Asimismo, la Figura 3 recoge el efecto de los 4 predictores más importantes de la respuesta al fracaso empresarial que se han identificado. Se trata de gráficos de dependencia parcial y representan el efecto marginal de cada variable en la probabilidad de que una empresa entre en una situación de concurso. Dicho de otra manera, cada gráfico ilustra la dependencia parcial que tiene una variable independiente en el modelo resultante, después de tener en cuenta el efecto en conjunto y promediado de las otras variables independientes. Aunque la forma de estos gráficos no proporciona una explicación muy clara, sí que recoge la tendencia general y pueden utilizarse para interpretar el efecto de los predictores en la variable de respuesta (Friedman, 2002 y Natekin and Knoll, 2013). La curva descendente de los gráficos ROT1 (ventas/activo total) y REN4 (resultado del ejercicio/ventas), indica que cuanto mayores son estas ratios la probabilidad de que una empresa entre en una situación de concurso es menor. Por otro lado, la curva ascendente de los gráficos EF3 (gastos financieros/ventas) y ACT1 (valor añadido/ventas), significa que un aumento de estas ratios lleva asociado una mayor probabilidad de fracaso empresarial.


Estos resultados son totalmente consecuentes con la realidad empresarial. ROT1 (rotación global del activo) es un potente indicador de la eficiencia de la compañía. Compara la cifra de ventas con la inversión efectuada para alcanzarla midiendo el número de veces que se recupera el activo vía ventas. Cuanto mayor sea su valor, mayor será la eficiencia o productividad de los activos comprometidos en el negocio.

Por su parte la ratio REN4 representa el *margen económico sobre ventas*, equivalente a la proporción de ganancia obtenida por cada euro facturado. Es un componente de la rentabilidad económica, junto a ROT1. Cuanto mayor sea su valor mayor será la rentabilidad económica y la empresa gozará de una mejor situación financiera

La ratio EF3 (gastos financieros/ventas) mide la relación entre los gastos financieros incurridos y las ventas obtenidas durante ese período en el que se generó el gasto financiero. Valores altos nos alertan de que los gastos financieros son excesivos pues la empresa está incurriendo en un gasto mayor de las ventas que obtiene. Por tanto, su crecimiento es acorde con situaciones de posible dificultad financiera.

Finalmente ACT1 representa el valor añadido respecto a las ventas y sintetiza la capacidad de generación de rentas por unidad de producto vendida. Si la ratio aumenta puede ser debido a una caída de las ventas lo que puede ser representar el inicio de procesos de inestabilidad financiera. Por tanto, el resultado estadístico es acorde con la realidad empresarial.

Figura 3. Gráficos de dependencia parcial



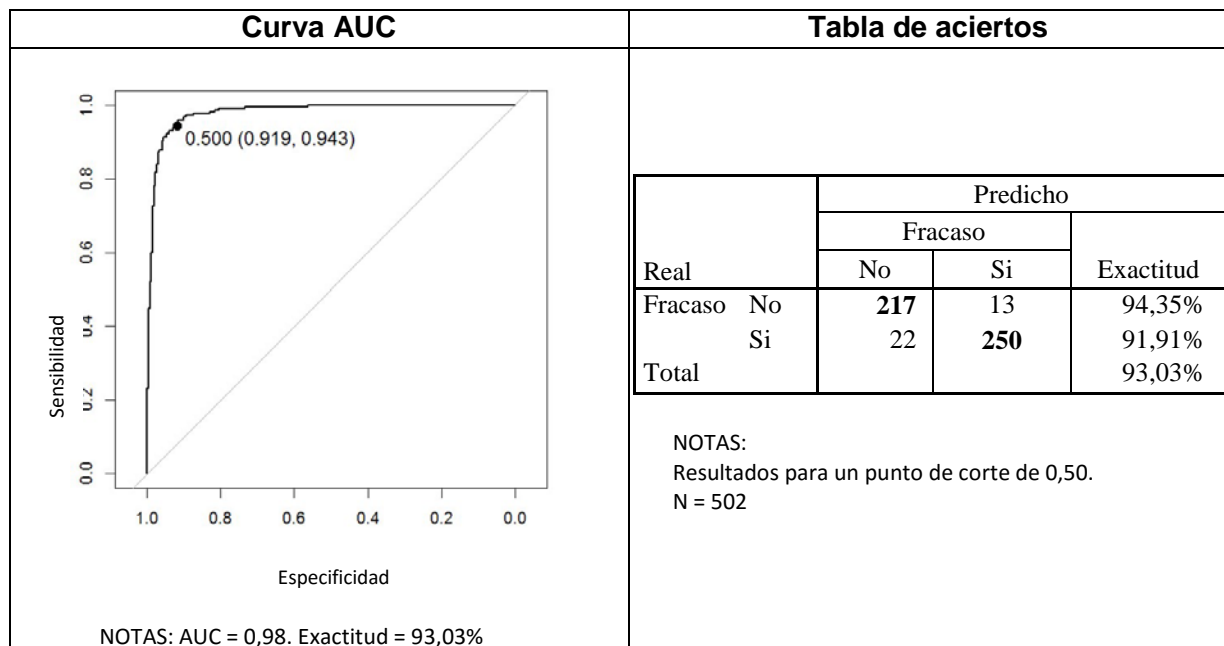
Precisión del modelo y capacidad predictiva

A continuación, calcularemos el valor del AUC sobre una muestra de validación, es decir, sobre un conjunto de datos que no se ha empleado para formular el modelo que hemos obtenido mediante BRT. Para tal fin la muestra total de 2.083 empresas la

hemos dividido en dos grupos aleatoriamente, con el 75% y 25% de observaciones cada uno. El grupo mayor se ha utilizado para entrenar el modelo BRT que hemos obtenido y explicado en líneas anteriores. El modelo resultante, con los parámetros seleccionados y con un peso determinado de los predictores —según se recoge en las Figuras 1 y 2—, se ha aplicado sobre 25% de las observaciones restantes, que constituye la muestra de validación.

La Figura 4 recoge los resultados de aplicar el modelo BRT sobre la muestra de validación. El valor del estadístico AUC es de 0,98 lo cual significa que el modelo funciona muy bien y es capaz de clasificar correctamente prácticamente la totalidad de las empresas como en situación de activo o de concurso de acreedores. La curva ideal AUC se extendería y alcanzaría el extremo superior izquierdo; por tanto, cuanto mayor sea el área de debajo de la curva mejor es entonces el algoritmo del clasificador y el AUC tomaría un valor de 1. La gráfica muestra también la sensibilidad —el porcentaje de aciertos del evento de interés— y especificidad —el porcentaje de aciertos del evento que no es de interés— del modelo para un punto de corte del 0,5, como probabilidad de corte para que el modelo realice su labor de clasificación entre los dos tipos de empresas. En la parte de la derecha, la tabla de aciertos refleja que el porcentaje global de aciertos es de un 93,03%. También se extrae que se clasifican correctamente un 94,35% de las empresas en activo —especificidad del modelo— y un 91,91% de las empresas en situación de concurso —sensibilidad del modelo—. Estos resultados obtenidos con la muestra de validación vienen a demostrar que el modelo BRT, que se ha perfilado con la muestra de entrenamiento, tiene un nivel de precisión muy elevado y una capacidad predictiva también muy alta, sobre unos datos que no se han empleado para su elaboración.

Figura 4. Precisión del modelo BRT en la muestra de validación



Comparación del modelo BRT con otros modelos dos y tres años anteriores al fracaso

El modelo BRT que se ha obtenido se ha realizado con datos de un año anterior a la fecha de declaración de la situación de concurso. Ahora nos apartaremos de esta fecha dos y tres años atrás con la finalidad de comprobar cómo varía la capacidad predictiva de los modelos resultantes a medida que nos alejamos en el tiempo del evento del fracaso.

La Figura 5 recoge la curva AUC y la importancia de las variables cuando nos situamos a dos años del evento de concurso de acreedores (N-2). La exactitud global del modelo para la muestra de validación es del 89,57% de los casos y el valor de AUC es de 0,96. Si nos alejamos un año más (N-3) entonces estos indicadores empeoran todavía un poco más en relación con los obtenidos a un año del fracaso (N-1). Para la muestra de validación la exactitud global del modelo es del 88,56% y el valor de AUC 0,95 (Figura 6). En definitiva, se aprecia que a medida que nos alejamos de la fecha del fracaso la capacidad predictiva de los modelos va reduciéndose. Las Figuras 5 y 6 en el panel derecho también recogen la importancia de las variables de estos modelos.

Figura 5. Precisión del modelo BRT en la muestra de validación año N-2

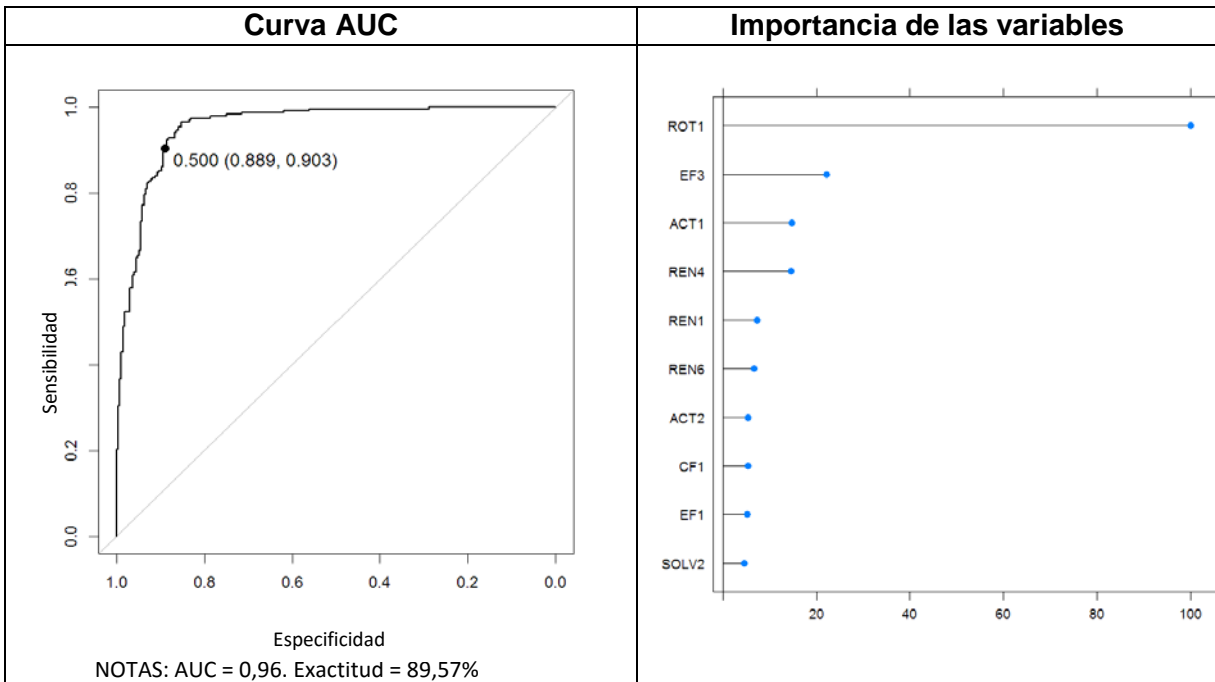


Figura 6. Precisión del modelo BRT en la muestra de validación año N-3

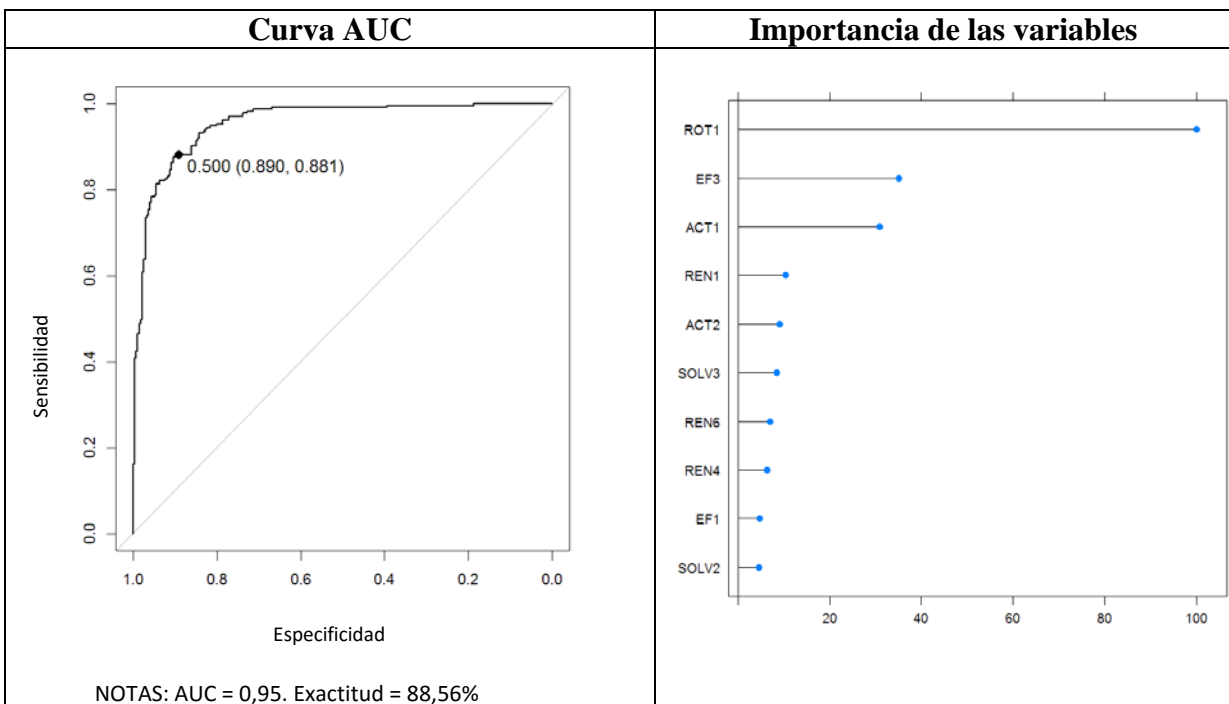



Figura 7. Estimación de la precisión mediante intervalos de confianza



Por último, con el fin de corroborar la pérdida de capacidad predictiva de los modelos cuanto más se aleja la fecha del concurso de acreedores, se han confeccionado intervalos de confianza con los datos muestrales del estadístico AUC que se obtuvieron para identificar los parámetros óptimos de los tres modelos mediante la técnica de validación cruzada. Esta validación se realizó con $k = 10$, por tanto se dispone de 10 observaciones muestrales del estadístico AUC para cada uno de los tres años considerados. Los intervalos de confianza resultantes (Figura 7) confirman que efectivamente tiene lugar una pérdida de capacidad predictiva de los modelos a medida que nos alejamos en el tiempo de la fecha del concurso de acreedores. Autores como Hothorn et al. (2005) y Eugster et al. (2008), defienden esta metodología para comparar la capacidad predictiva de diferentes modelos.

5.- CONCLUSIONES

En este estudio hemos tratado de obtener un modelo que nos permitiese clasificar entre empresas sanas y en peligro de quiebra, utilizando la metodología Boosted Regression Trees, BRT extraída de las técnicas de Machine Learning, basada en los árboles de regresión potenciados. Como variables independientes se han considerado diferentes ratios económico-financieros obtenidos de la información proporcionada por

el balance y la cuenta de resultados de los tres años anteriores a la fecha del fracaso de las sociedades, tomando como año en consideración el 2013. Asimismo, los resultados que se presentan se han obtenido a partir de una muestra de validación que no se ha utilizado para elaborar y encontrar los parámetros óptimos de los modelos obtenidos, de lo contrario podríamos haber incurrido en problemas de sobreajuste y los resultados no serían generalizables.

BRT permite obtener modelos de predicción muy precisos pues potencia las características más relevantes de dos algoritmos. Por un lado, los árboles de decisión individuales que predicen la respuesta de una variable de clasificación mediante la utilización de distintos nodos y hojas terminales; y, por otro lado, *boosting*, un método que va mejorando los resultados a partir de la agregación de árboles de decisión que van reduciendo progresivamente los errores del modelo.

Los modelos de predicción estimados con los datos de los tres años anteriores al fracaso alcanzan porcentajes de acierto superiores a los obtenidos en estudios anteriores, que van desde el 93,03% del año previo al fracaso, al 88,56% del tercer año. Al igual que sucede en otros trabajos que estudian el fracaso empresarial el porcentaje global de aciertos disminuye a medida que el modelo se aleja en el tiempo de la fecha de fracaso.

En los tres años anteriores al fracaso resulta determinante en el modelo de predicción la variable que mide la rotación de las ventas sobre el activo total, indicativa de la rentabilidad y eficiencia de la empresa, siendo mucho más relevante el año justamente anterior. En segundo lugar, pero con mucha menos influencia estaría una variable de la estructura financiera que compara los gastos financieros sobre las ventas. En el primer caso los mayores valores de esta ratio conllevan una menor probabilidad de que una empresa entre en una situación de concurso. En el segundo caso sus altos valores nos alertan de que los gastos financieros son excesivos pues la empresa está incurriendo en un gasto mayor de las ventas que obtiene, situación acorde con la que presentan empresas con dificultades financieras.

La ratio de actividad valor añadido sobre ventas sería la tercera variable más influyente dos y tres años antes del fracaso, siendo la cuarta el año previo al fracaso. Otra ratio muy influyente es la de rentabilidad que compara el resultado del ejercicio sobre las ventas, aunque el tercer año previo al fracaso es más influyente la rentabilidad comparando el resultado del ejercicio sobre el activo total. Como es lógico, a mayor rentabilidad menor probabilidad de fracaso, mientras que un aumento del

valor añadido sobre las ventas lleva asociado una mayor probabilidad de desencadenar una situación concursal.

Hemos de advertir que estos modelos pueden aplicarse por los usuarios para diagnosticar si una empresa, a partir de su información económica y financiera, presenta síntomas que podrían derivar en una situación de fracaso, pero con la cautela de que en este diagnóstico no se tienen en cuenta otras circunstancias de tipo cualitativo que no se pueden incorporar en el modelo y que podrían incidir de manera decisiva. Por lo tanto, debe entenderse como un aviso que haga sospechar de la posibilidad de fracasar, siendo necesario un análisis más detallado de la verdadera situación de la empresa.

BIBLIOGRAFÍA

Alfaro Cortés, E. (2006). Combinación de clasificadores mediante el método boosting. Una aplicación a la predicción del fracaso empresarial en España. *Ediciones de la Universidad de Castilla-La Mancha*, Tesis doctoral, Cuenca.

Bell, T.B., Ribar, G.S. y Verchio, J. (1990) Neural Nets Versus Logistic Regression: A Comparison of Each Model's Ability to Predict Commercial Bank Failures, en Auditing Symposium on Auditing Problems, Srivastava, R.P. pp. 23-53.

Bhargava, M., Dubelaar, C. y Scott, T. (1998). Predicting Bankruptcy in the Retail Sector: An Examination of the Validity of Key Measures of Performance, *Journal of Retailing and Consumer Services*, V. 5 (2), pp. 105-117.

Chambers, M. y Dinsmore T. W. (2015). *Advanced Analytics Methodologies: Driving Business Value with Analytics*, Pearson Education, New Jersey,

Cortes, C. y Mohri, M. (2004). AUC optimization vs, error rate minimization, *Advances in neural information processing systems*, V,16 (16), pp. 313-320,

Diéguez, J., Trujillo, F. y Cisneros, A.J. (2006). Modelos de predicción de la insolvencia empresarial: la incorporación de ratios a partir de un marco teórico, *VI Jornadas sobre Predicción del Insolvencia Empresarial*. Carmona.

Elith, J., Leathwick, J. R. y Hastie, T. (2008). A working guide to boosted regression trees, *Journal of Animal Ecology*, V. 77, pp. 802-813.

- Eugster, M. J., Hothorn, T., y Leisch, F. (2008). Exploratory and inferential analysis of benchmark experiments. Ludwigs-Maximilians-Universität München, Department of Statistics, Tech. Rep, 30.
- Friedman J. (2001). Greedy Function Approximation: A Gradient Boosting Machine, *Annals of Statistics*, V. 29 (5), pp. 1189–1232,
- Friedman, J. H. (2002). Stochastic Gradient Boosting, *Journal of Computational Statistics & Data Analysis*, V. 38 (4), pp. 367–378.
- Hastie, T., Tibshirani, R. y Friedman, J. (2009). The Elements of Statistical Learning, Springer, New York.
- Hothorn, T., Leisch, F., Zeileis, A., y Hornik, K. (2005). The design and analysis of benchmark experiments. *Journal of Computational and Graphical Statistics*, 14 (3), pp. 675-699.
- James, G, Witten, D., Hastie, T. y Tibshirani, R. (2013). An Introduction to Statistical Learning, 2nd Edition, Springer, New York.
- Kuhn, M, y Johnson, K. (2013). Applied Predictive Modeling, Springer, New York.
- Kuhn, M, y otros colaboradores (2016). Caret: Classification and Regression Training, R package version 6,0-64, <http://CRAN.R-project.org/package=caret>
- McLealy, S. y Omar, A. (2000). The sensitivity of prediction models to the non-normality of bounded and unbounded financial ratios, *British Accounting Review*, 58 (2), pp. 228-246.
- Momparler, A., Carmona, P. y Climent, F.J. (2016). La predicción del fracaso bancario con la metodología Boosting Classification Tree, *Revista Española de Financiación y Contabilidad*, V. 45, (1), pp. 63-91.
- Natekin A, y Knoll, A. (2013). Gradient Boosting Machines, A Tutorial, *Frontiers in Neurorobotics*, V. 7 (21).
- R Core Team (2015). R: A language and environment for statistical computing, R Foundation for Statistical Computing, Vienna, Austria, URL <http://www.R-project.org/>,
- Rahminian, E., Singh, S., Thammachote, T. y Virmani, R. (2000). Bankruptcy Prediction by Neural Networks, en R.R. Trippi y E. Turban [ed.]: *Neural Networks in Finance and Investing*, Homerwood, IL, Irwin, pp. 175-332.
- Ridgeway, G, (2015). Gbm: Generalized Boosted Regression Models, R package version 2,1,1, <http://CRAN.R-project.org/package=gbm>

Ridgeway, G. (2009). Generalized Boosted Models: A Guide to the gbm Package, URL https://r-forge.r-project.org/scm/viewvc.php/*checkout*/pkg/inst/doc/gbm.pdf?revision=18&root=gbm&pathrev=22

Schapire, R. (2003). The boosting approach to machine learning - an overview, MSRI Workshop on Nonlinear Estimation and Classification, 2002 (eds Denison, D.D., Hansen, M.H., Holmes, C., Mallick, B. y Yu, B.), Springer, New York,