
Modelos no paramétricos en la determinación del *spread* en un mercado primario de renta fija

María BONILLA MUSOLES

Universidad de Valencia. Facultad de Economía
maria.bonilla@uv.es

Leandro GARCÍA MENÉNDEZ

Universidad de Valencia. Facultad de Economía
leandro.garcia@uv.es

M^aLuisa MARTÍ SELVA

Universidad de Valencia. Facultad de Economía
mamarsel@esp.upv.es

Rosa PUERTAS MEDINA

Universidad de Valencia. Facultad de Economía
rpuertas@esp.upv.es

Resumen: Recientemente se han propuesto diversos modelos no paramétricos para la resolución de problemas de predicción en el entorno bancario, obteniendo potentes estimadores. En el presente trabajo se proponen dos algoritmos no paramétricos, los *Árboles de Regresión* (CART) y los *Splines de Regresión Adaptativa Multivariante* (MARS), con objeto de medir su precisión en la determinación del precio de emisión en el mercado primario de eurobonos, realizando un análisis comparativo con un modelo paramétrico, una regresión lineal estimada por Mínimos Cuadrados Ordinarios (MCO). Además, se aborda el dilema de aprendizaje-generalización mediante la *validación cruzada* para, de este modo, establecer la estructura óptima de los algoritmos que nos permitirá obtener los mejores resultados en el problema que vamos a analizar. El estudio ha concluido que la predicción más potente del modelo CART es sobre el *spread* de las emisiones de los bancos y los soberanos, mientras que el MARS y la estimación por MCO han resultado más precisos en las emisiones de los bancos.

Clasificación JEL: C53, D81, G15.

Abstract: The recent proposal of various non-parametric models to solve prediction problems in banking has provided powerful estimators. This paper uses two non parametric models, *Classification and Regression Trees* (CART) and *Multivariate Adaptive Regression Splines* (MARS), in the eurobond market to measure the accuracy of both these methods in determining issue price in the primary market. Also the research included a comparative analysis with a parametric model, lineal regression estimated by *Ordinary Least Squares* (OLS). Furthermore, the learning-generalization dilemma is tackled by *cross-validation* in order to establish the most efficient algorithm structure for the solution of our problem. The study concludes that CART algorithm is best at banking and state sector spread prediction, while MARS algorithm and OLS estimates are more accurate at banking issues.

JEL Classification: C53, D81, G15.

1. INTRODUCCIÓN

En la literatura se han propuesto diversos modelos no paramétricos para la resolución de problemas de predicción en el entorno bancario, obteniendo potentes estimadores (Altman et al., 1994; Back et al., 1995; Varetto, 1998; Puertas, 2000). El presente trabajo utiliza los *Arboles de Regresión* (CART), los *Splines de Regresión Adaptativa Multivariante* (MARS) y la estimación por Mínimos Cuadrados Ordinarios (MCO) en el contexto del mercado de eurobonos, con objeto de medir la precisión de estos métodos en la determinación del *spread* de las emisiones.

La motivación del estudio realizado es doble. En primer lugar, determinar el comportamiento del CART y del MARS frente a la estimación por MCO, en un nuevo ámbito de aplicación, la predicción de los *spreads* en las emisiones de bonos internacionales, contribuyendo, de este modo, a la discusión de su validez como técnicas de predicción. En segundo lugar, dado que muchos de los estudios realizados no abordan con suficiente cuidado el dilema de *aprendizaje-generalización*, es decir, muestran unos resultados en una situación particular para la cual el modelo ofrece una buena capacidad predictiva, pero que en ningún caso respondería a su estructura óptima, introducimos la *validación cruzada* como metodología para superar tales deficiencias.

La estructura seguida en el desarrollo del estudio es la siguiente: en la sección 2, se motiva el estudio realizado describiendo las variables y muestra empleada en el análisis empírico. En la sección 3, se explican los fundamentos teóricos de las técnicas no paramétricas, haciendo especial referencia sobre el CART, MARS y método de *validación cruzada* utilizado para obtener la estructura óptima del modelo. En la sección 4, presentamos los resultados obtenidos, para finalizar en la sección 5 con las principales conclusiones.

2. MOTIVACIÓN: VARIABLES Y MUESTRA

Los eurobonos objeto de análisis son únicamente a tipo fijo, por ser los más importantes dentro de los mercados de renta fija internacionales, y además porque nos interesa su carácter de mercado "casi perfecto". Dicho carácter es debido a sus particularidades sobre la exención de impuestos, emisiones anónimas de gran tamaño e inexistencia de un organismo regulador.

El estudio de los precios de las emisiones de eurobonos, siguiendo a Finnerty y Nunn (1985), Kidwell et al. (1985) y Martí (2001), está fundamentado en la construcción de modelos donde se considera como variable dependiente el *spread* de las emisiones en el mercado primario, y como independientes una serie de características propias de la emisión y del emisor.

El diferencial o *spread* sobre la TIR (tasa interna de rendimiento) es definido como la diferencia entre el tipo libre de riesgo (*swap*¹) y la rentabilidad de un título con riesgo (*TIR*). En las emisiones de eurobonos, constituye normalmente el factor más importante de remuneración para los inversores y, en consecuencia, el principal elemento de negociación con el emisor.

$$\text{Spread} = \text{TIR} - \text{swap} \quad (1)$$

1 Considerado como la rentabilidad obtenida en el mercado de *swap* para la misma moneda de la emisión, la misma duración y la misma semana de la emisión. El tipo *swap* utilizado es el promedio entre el tipo de oferta y el tipo de demanda.

La *TIR* de una emisión no siempre es superior al *swap*, es decir, un emisor puede fijar la rentabilidad por debajo del nivel imperante en el mercado de *swap*, y en tal caso se está beneficiando de una situación aventajada, emitiendo así de una forma más rentable (desde el punto de vista del emisor).

En el trabajo se ha realizado una reescalación de 0,01 a 100 para los datos del *spread* y posteriormente, se ha calculado su inversa, de manera que la distancia entre ellos se mantiene sin alterar los resultados. Los datos mínimos que aparecen en la Tabla 2 corresponden al *spread* más alto (1/100), mientras que los valores máximos corresponden al *spread* original más bajo.

Los modelos explicativos del *spread* sobre bonos (domésticos e internacionales) encontrados en la literatura no siguen una estructura unánime en cuanto a las variables utilizadas, tal y como mostramos en el siguiente cuadro resumen donde exponemos una revisión bibliográfica de diferentes trabajos que han analizado el precio de títulos en el euromercado.

Como observamos en los artículos referenciados en el Cuadro 1 que explican el *spread* de los eurobonos, se aplican técnicas paramétricas, sin haber encontrado en la literatura ninguna aplicación de métodos no paramétricos en el ámbito del mercado de eurobonos.

Tras la variedad de modelos encontrados para la explicación del *spread*, en esta investigación incorporamos un conjunto de hipótesis referentes tanto a variables financieras, como variables macroeconómicas determinando el modelo que supone la base de los estudios empíricos realizados en este trabajo. La selección de dichas variables ha sido realizada siguiendo, en todo momento, los postulados teóricos sobre los precios de los eurobonos.

$$\text{Spread} = f(\text{rating}, \text{tamaño}, \text{duration}, T, \text{interés}, \text{PIB}, \text{riesgo país}) \quad (2)$$

2.1 Variables financieras:

Hipótesis 1: El papel del rating

El *rating* es una variable importante y tradicionalmente utilizada en la literatura para la formación del *spread* de una emisión de bonos (Leibowitz *et al.*, 1990; Duffee, 1998; Datta *et al.*, 1999; Okashima y Fridson, 2000). Se entiende que un eurobono perteneciente a un emisor con alta calificación crediticia tendrá un *spread* reducido (existe una relación inversa entre el *spread* y el *rating*), debido a que el inversor no está soportando demasiado riesgo de impago. Siguiendo a Kish *et al.* (1999) podemos definir el *rating* como la variable que permite valorar la probabilidad de insolvencia de una emisión de bonos, mostrando la evidencia empírica que es un buen predictor de impagos en promedio².

En nuestra investigación, cuantificamos el *rating* siguiendo un estudio realizado por Theobald (1997) relacionado con el riesgo crediticio de la deuda soberana y supranacional en el mercado de bonos corporativos de EEUU a 10 años. Para ello, hemos construido una función

2 El *rating* o la probabilidad de *default* es uno de los componentes que forman el riesgo de crédito junto con la exposición o el importe en riesgo y la tasa de recuperación. En el trabajo los datos del *rating* han sido obtenidos, principalmente, de la agencia S&P pero en caso de no tener calificación de dicha agencia para determinados emisores hemos utilizado los datos de Moody's. Según la literatura no existen diferencias significativas entre las calificaciones dadas por estas agencias.

Cuadro 1
Revisión bibliográfica sobre los modelos explicativos del spread

Autor	Modelo	Muestra	Técnica de estimación	Resultados
Kidwell et al (1985)	Costes = f (Tamaño, rating, call, T.int, volatilidad, forma venta, sector, eurobonos)	229 emisiones bonos de empresas publicas en el euromercado y mercado doméstico durante 1979 y 1983	MCO	Las emisiones de eurobonos nos ahorran costes respecto a las domésticas. El modelo explica el 60% de los costes El rating, la amortización anticipada y la forma de venta presentan signos negativos, mientras que el tamaño, el tipo de interés y la volatilidad son positivos
Finnerty y Nunn (1985)	Spread = f (tamaño, cupon, crecimiento PIB)	500 emisiones eurobonos durante 1972 - 1982	MCO	Los spreads de eurobonos son menores que los spreads de los bonos domésticos. Los costes de suscripción son más altos en los eurobonos que en los bonos domésticos Los inversores evalúan al rating de diferente forma, para los diferentes títulos.
Bradley (1991)	Precio = f(Market makers, seguridad título, emisor, rating, garantía, warrant, liquidez, tamaño, nacionalidad, forma de registro, frecuencia cupon, emitido Antillas holandesas, denominacion mínima, tipo cambio)	289 emisiones eurobonos entre 1984 y 1987	MCO	El nombre del emisor es muy influyente en la valoración del título del eurobono, porque los resultados entre unos y otros presentan mucha dispersión.
Adedeji y McCosh (1995)	Rentabilidad = f (frecuencia pago interés, vencimiento, rating, seguridad, efecto país)	3860 emisiones eurobonos durante 1989 y 1991	MCO	Los bonos sin clasificación crediticia tienen mejor rentabilidad que los bonos con rating. El país del emisor es importante para determinar la rentabilidad del título
Clare et al (2000)	Rentabilidad = f(rating, T. Cambio, inflación, índice mercado)	20 carteras de eurobonos a tipo fijo durante 1992 – 1997.	MCO	El poder explicativo del modelo está comprendido entre un 32% a un 66% variando según las carteras. Todas las variables son significativas con los signos esperados.

con variaciones muy pequeñas en los valores asignados al grado de inversión, mientras que van incrementándose en los valores que forman el grado especulativo de la escala, resolviendo así mediante una exponencial³ el recorrido asignable al *rating*.

Hipótesis 2: El papel del tamaño de la emisión

Desde el punto de vista del emisor, el tamaño de la emisión viene determinado por sus necesidades de financiación, así como por las oportunidades existentes en cada momento en el mercado. Los prestatarios deben considerar la magnitud de la emisión en relación con las manejadas en diferentes mercados. De esta forma, en Nueva York y Londres, es habitual realizar emisiones de gran tamaño (200 millones de dólares), por lo que el coste de la operación, es menor que en otros mercados donde las emisiones de dicho tamaño son menos frecuentes.

Sin embargo, desde el punto de vista de los inversores un mayor tamaño tiende a garantizarles un mejor grado de liquidez de la emisión en el mercado secundario, haciéndola más atractiva. De manera que dicha variable está inversamente relacionada al *spread*, puesto que a mayor tamaño el emisor puede presionar a la baja la rentabilidad y obtener un menor diferencial.

Por otra parte, en el caso de las emisiones privadas (con volumen inferior a 100 millones de dólares), al estar adaptadas a las condiciones que requiere el inversor, dan lugar a un margen de negociación más amplio sobre la rentabilidad de la emisión. De tal forma que en esta situación el volumen sería una variable directamente relacionada con el *spread*.

Hipótesis 3: El papel de la duration

La *duration* es el instrumento financiero adecuado para capturar el riesgo de mercado, reflejando la verdadera "vida media" de un título. Representa una media ponderada de los vencimientos de los préstamos individuales correspondientes con cada pago futuro (Clark *et al.*, 1993 y Van Horne, 2001). Por este motivo, la *duration*⁴ de un bono con pago periódico de cupones y un período de amortización finito y superior a la unidad, es menor que su período de amortización.⁵

En el trabajo consideramos una ETTI (Estructura Temporal de los Tipos de Interés) plana con el fin de superar determinadas limitaciones de la *duration*⁶, de tal manera que la actualización de

3 La función exponencial para la cuantificación del rating es $f(x) = 100,125 - 100 e^{-x^{2,84}}$ donde $x = 18,17, \dots, 0$ según la categoría Aaa, Aa1, ..., c.

4 La *duration* según el trabajo pionero de Macaulay (1938) se calcula a través de la siguiente expresión:

$$D = \left(\sum_{j=1}^n t_j \left(\frac{C_j / (1+R)^{t_j}}{P} \right) \right) = \sum_{j=1}^n [t_j \cdot w_j]$$

donde: **tj**: vencimiento del j-ésimo pago generado por el título

Cj: cuantía del j-ésimo pago generado por el título.

R: TIR del título correspondiente a la unidad de tiempo utilizada para medir los vencimientos.

Wj: ponderación correspondiente al capital j-ésimo de la corriente de pagos (se verifica que la suma de todos los w_j es igual a la unidad).

P: precio del título

D: *duration* del título

5 Sólo la *duration* es igual a la amortización cuando el cupón es cero o cuando tiene pago periódico de cupones con un solo vencimiento pendiente.

6 Ver Meneu *et al* (1992)

todos los cupones es realizada a través de la *TIR* de la emisión (es decir, una tasa idéntica para todos los años). Desde un punto de vista teórico, tal y como muestran en su investigación Litterman e Iben (1991), y de forma generalizada la literatura, la *duration* para las emisiones pertenecientes al grado de inversión es una variable directamente relacionada con el *spread*, porque cuanto más tiempo transcurre hasta el vencimiento, la emisión tiene mayor riesgo de insolvencia.

Normalmente, existen en el mercado, emisiones de eurobonos con una *duration* entre 1 y 30 años. En el conjunto de las 2653 emisiones de la muestra utilizada en este trabajo, la *duration* media es de 4,14 años, siendo su desviación y varianza muy reducidas por lo que hay mucha concentración alrededor de la media. Además, como el conjunto de emisiones que forman la muestra de este estudio está englobado dentro del grado de inversión, teóricamente la *duration* de dichas emisiones tiene una relación positiva con el *spread*.

Dado que el ámbito de la investigación son los mercados financieros internacionales, también incluimos como variables explicativas del *spread* aquellas que informan sobre la situación macroeconómica del país del emisor.

2.2 Variables macroeconómicas:

Hipótesis 4: El papel del tipo de interés

En la literatura diversos trabajos han demostrado la influencia positiva y significativa del tipo de interés como variable explicativa del *spread*, por ejemplo Barnhill *et al.* (2000). En nuestro trabajo, para cada uno de los países de la muestra, el tipo de interés está referenciado al de los depósitos bancarios anuales, por ser un tipo muy correlacionado con el mercado de capitales. La base de datos utilizada para obtener dicho tipo de interés ha sido *Internacional Financial Statistics*.

Hipótesis 5: El papel del PIB

En épocas de expansión económica, en la que los beneficios empresariales aumentan de forma generalizada, las compañías tendrán menos dificultades para satisfacer sus compromisos financieros. Además, suelen haber revisiones al alza en el *rating* de las empresas, por ello, la prima de riesgo exigida por los inversores será más reducida, y disminuirá en mayor proporción para las empresas de peor calidad crediticia. La variable que representa el crecimiento del PIB es una tasa porcentual anual, considerando el año en que se había realizado la emisión. La base de datos utilizada para su obtención, al igual que en el tipo de interés, ha sido *Internacional Financial Statistics*.

Hipótesis 6: El papel del riesgo país

Algunos autores (Solnik, 1996; Scholtens, 1999) definen el riesgo país como la posibilidad de que el conjunto de los prestatarios de una determinada nación sean incapaces, en los momentos previamente establecidos para ello, de pagar los intereses y/o devolver el principal de sus deudas a sus acreedores extranjeros.

Aunque existen diversas publicaciones especializadas⁷, en los mercados financieros internacionales, que se ocupan de publicar clasificaciones de países en función de distintos indicado-

7 Entre otras cabe destacar "Euromoney" e "Institutional Investor"

res, hemos optado por los datos de Euromoney. Dicha publicación basa su sistema de clasificación en una combinación de datos objetivos e información subjetiva, esta última obtenida a través de una muestra de especialistas. Con esta forma de proceder se pretende atacar el problema que plantea la diversidad de los distintos países analizados, así como la distinta cantidad y calidad de información disponible en ellos. Según la cuantificación del riesgo país efectuada por *Euromoney*, el país con una puntuación mejor es el que menos riesgo está soportando y, por lo tanto, daría lugar a un menor *spread* en la emisión del país correspondiente. Es importante no confundir el riesgo país con la variable *rating*, dado que éste sólo pondera el 10% en la elaboración del riesgo país, según la metodología de *Euromoney* utilizada en el desarrollo del trabajo.

Expuestas las hipótesis de partida, estimamos el modelo (2) por MCO pudiendo concluir que dichas hipótesis se cumplen y permiten la elaboración óptima del trabajo empírico planteado en el estudio.

Tabla 1:
Resultados de la estimación por MCO

Variable	Coefficiente	T - Student
Constante	2,899	10,1
Duration	0,67	14,2
Tamaño	0,05	2,6
Daa1	0,06	1,89
Daa2	0,20	6,84
Daa3	0,18	6,05
Da1	0,34	9,36
Da2	0,54	10,6
Da3	0,45	6,39
Dbaa1	0,74	6,82
Dbaa3	1,05	5,17
Dbal	2,89	18,6
Dbal2	2,02	13,9
Dbal3	2,11	13,3
Db1	1,01	4,3
Db2	0,77	3,01
PIB	-0,03	-3,58
Tipo interés	0,01	6,18
Riesgo país	-0,04	-12,4
R ² =0,727		
F = 388,7		

En la Tabla 1 observamos como el conjunto de variables financieras y macroeconómicas, consideradas en el modelo dan lugar a una buena estimación del *spread*, $R^2=0,727$. Los resultados obtenidos de los coeficientes de cada variable indican que la *duration* es la variable más influyente sobre el *spread* seguida del tamaño y el riesgo país.

Respecto al *rating*, su significatividad ha sido analizada para cada una de las categorías del mismo a través de *dummies* cuya variable de referencia es la AAA. Todas ellas han resultado ser significativas respecto al *spread*, y su signo positivo ha de ser interpretado por cuanto pagan de más respecto a la AAA las categorías que se sitúan por debajo de la misma.

La muestra está fundamentada en un conjunto de 2653 emisiones de eurobonos a tipo fijo, negociadas en el mercado primario durante el periodo 1995-1999. Los estadísticos descriptivos de la variable dependiente se recogen en la Tabla 2.

Tabla 2
Estadísticos descriptivos del spread

	Spread			
	Bancos	Empresas	Serv.Financieros	Estados
Mínimo	0,0100	0,0100	0,0100	0,0100
Máximo	0,5000	1,3000	0,7000	0,8000
Media	0,0302	0,0438	0,0429	0,0515
Desviación	0,0110	0,0423	0,0283	0,0478
Varianza	0,0008	0,0139	0,0053	0,0059
Mediana	0,0250	0,0186	0,0275	0,0233

Las observaciones pertenecientes a la muestra han sido obtenidas de la base de datos *Reuters*, estableciendo para su extracción los siguientes criterios de selección: a) emisiones sin cláusulas de amortización anticipada, ni otro tipo de amortización periódica, b) emisiones con cupón y principal denominados en la misma moneda, y c) emisiones pertenecientes a los sectores bancos, Estado, empresas y servicios financieros.

En el conjunto de emisiones es el sector bancos el que incluye un mayor número de emisiones (59%), seguido del sector Estado (20,27%), y el resto lo forman el sector empresas (12,89%) y el sector servicios financieros (7,84%).

El mercado de eurobonos está caracterizado por ser *off-shore*, ya que no conoce fronteras en la realización de sus emisiones. Es por ello que en la muestra tenemos emisores pertenecientes a 22 países diferentes. De todos ellos, únicamente 5 emisores pertenecen a países emergentes y 17 pertenecen a países desarrollados. Y, dentro de éstos últimos, los que han realizado un mayor número de emisiones son EEUU y Alemania con un 22,07% y 21,5% del total de emisiones, respectivamente.

Las emisiones, en general, están bastante distribuidas entre las carteras⁸ de la muestra, la que mayor porcentaje representa, con un 8,11%, es la perteneciente al emisor "General Electric Capital Corp" siendo clasificada como una empresa americana. Y en segundo lugar, se encontraría el banco de Reino Unido "Abbey Nacional Treasury Services Plc" representando sus emisiones un 4,41% del total de emisiones.

8 Una cartera es el conjunto de emisiones realizadas por un mismo emisor.

La cantidad de emisiones realizadas de un año a otro no presenta una diferenciación significativa. El año en que se realizaron un mayor número de emisiones fue en 1996 con un 24,31% sobre el total de emisiones, y el que menos en 1998 con un 17,53%. Esto significa, dado que tenemos a los mismos emisores todos los años, que el número de emisiones realizadas por estos no varía considerablemente de un año a otro.

3. MODELOS DE PREDICCIÓN NO PARAMÉTRICOS

Como es sabido, los problemas de estimación y predicción pueden ser tratados por una gran variedad de técnicas estadísticas que, dependiendo del conocimiento o no de la forma funcional que explica la variable dependiente, se clasifican en paramétricos y no paramétricos. Los modelos paramétricos parten de una función de distribución conocida, y reducen el problema a estimar los parámetros que mejor ajusten las observaciones de la muestra. Dichos modelos resultan muy potentes cuando el proceso generador de datos sigue la distribución propuesta, aunque pueden llegar a ser muy sensibles frente a la violación de las hipótesis de partida, cuando se utilizan muestras de reducido tamaño.

Con objeto de salvar ésta y otras limitaciones, se emplean los denominados modelos no paramétricos, conocidos también como métodos de distribución libre, debido a que no se encuentran sujetos a ninguna forma funcional. Dichos modelos presentan pocas restricciones, por lo que en ocasiones resultan más fáciles de aplicar que los paramétricos y permiten "reconstruir" la función de distribución en todo tipo de situaciones, incluidas aquellas en las que la forma funcional sea sencilla y conocida (por ejemplo, lineal). Otra gran ventaja de los métodos no paramétricos es su capacidad para detectar posibles *outliers* que pudieran existir en la muestra.

Así pues, la diferencia fundamental entre los modelos paramétricos y no paramétricos es la siguiente. Supongamos que la variable dependiente Y puede ser explicada mediante la expresión:

$$Y = f(x_1, x_2, K, x_k) + \varepsilon \quad (3)$$

donde, x_i : variables explicativas,

ε : perturbación aleatoria

$f(x)$: relación existente entre las variables utilizadas.

Los modelos paramétricos suponen conocida la forma funcional de $f(x)$, reduciéndose el problema a determinar los parámetros que la definen. Por su parte, los modelos no paramétricos emplean formas funcionales flexibles que permiten formular una función $\hat{f}(x)$, de manera, que sea una buena aproximación de $f(x)$. Es decir, el problema consiste en calcular los parámetros de una función $\hat{f}(x)$, y no los parámetros de una función conocida. En ambos casos es necesario estimar los parámetros de los que depende la forma funcional. Sin embargo, en el caso de los modelos paramétricos, la elección de dicha forma funcional se establece a priori, por lo que una elección inadecuada se traducirá en un modelo que no ajuste los datos (por ejemplo, supuesta una relación lineal entre las variables, dicha función presentará un mal ajuste cuando la respuesta es, entre otras, cuadrática).

Dadas las características del problema que nos proponemos analizar, (determinación del *spread* a partir de un conjunto de variables financieras y macroeconómicas), los modelos paramétricos podrían parecer, a priori, que no poseen la flexibilidad suficiente para ajustarse a todo tipo de situaciones. Por otra parte, y en lo que respecta a su capacidad predictiva, existen algunos estudios que demuestran su inferioridad frente a los modelos no paramétricos (Tam y Kiang, 1992; Altman *et al.*, 1994).

La muestra utilizada en la investigación es de carácter financiero y macroeconómico, recogiendo valores históricos de los años 90, por lo que es importante poder evitar posibles datos irregulares que pudieran distorsionar los resultados. Como ya se citó anteriormente, los modelos no paramétricos poseen la capacidad de detectar y evitar que estas observaciones puedan afectar a las predicciones, lo que supone una gran ventaja frente a los paramétricos.

En el análisis empírico hemos utilizado como modelos no paramétrico los algoritmos CART y MARS, los cuales recientemente han sido utilizados con éxito en problemas de clasificación⁹. El interés de este estudio se centra en analizar su precisión como modelos de regresión con objeto de determinar su potencia en la predicción del *spread* de las emisiones de eurobonos a tipo fijo, y poderla comparar con una regresión lineal estimada por MCO.

3.1 Método de Partición Recursiva: Árboles de clasificación y regresión (CART)

Los árboles de decisión son una técnica no paramétrica que reúne las características del modelo clásico univariante y las propias de los sistemas multivariantes. Originariamente fueron propuestos para separar las observaciones que componen la muestra asignándolas a grupos establecidos a priori, de forma que se minimizara el coste esperado de los errores cometidos. Esta técnica fue presentada por Friedman en 1977, pero originariamente sus aplicaciones a las finanzas no fueron muy numerosas, si bien cabe destacar dos estudios pioneros: Frydman et al. (1985) en el que utilizan el modelo para clasificar empresas, comparando su capacidad predictiva con el análisis discriminante, y Marais et. al (1984) que, por el contrario, lo aplican a préstamos bancarios. En ambos trabajos se ha llegado a demostrar la gran potencia que presenta este algoritmo como técnica de clasificación.

El modelo CART supone esencialmente que las observaciones son extraídas de una distribución ϕ en $L \times X$, donde L es el espacio de categorías, y X el espacio de características. Las densidades condicionales $\phi(x|l)$ difieren al variar l , y las probabilidades marginales $\phi(l)$ son conocidas. El proceso utiliza la muestra S como conjunto de entrenamiento para la estimación no paramétrica de una regla de clasificación que permita particionar directamente el espacio X de características. Para cada l de L , el subconjunto S_l del conjunto de entrenamiento S constituye una muestra aleatoria de la distribución condicional $\phi(x|l)$ en X .

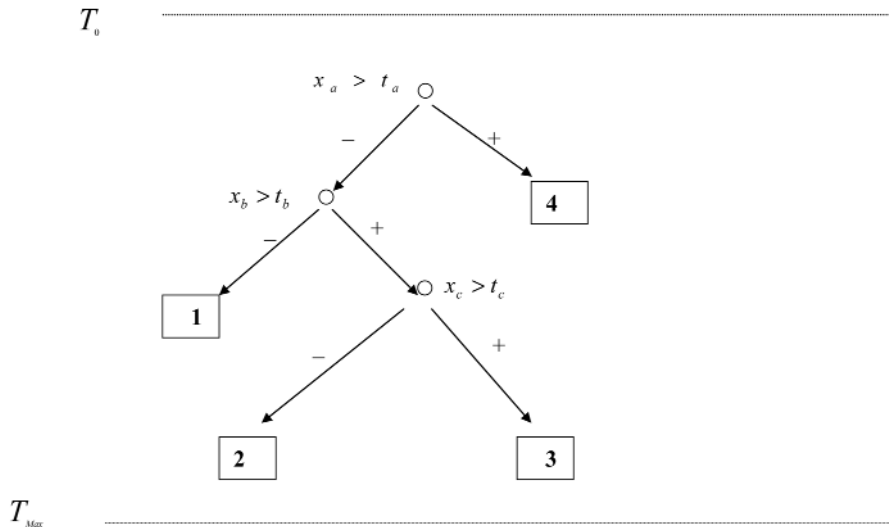
Así pues, el proceso consiste en dividir sucesivamente la muestra original en submuestras, sirviéndose para ello de reglas univariantes que buscarán aquella variable independiente que permita discriminar mejor la división. Con ello, se pretende obtener grupos compuestos por observaciones que presenten un alto grado de homogeneidad, incluso superior al existente en el grupo de procedencia (denominado *nodo madre*).

Con objeto de encontrar la mejor regla de división, el algoritmo estudiará cada una de las variables explicativas, analizando los puntos de corte para, de este modo, poder elegir aquella que mayor homogeneidad aporte a los nuevos subgrupos. El proceso finaliza cuando resulte imposible realizar una nueva división que mejore la homogeneidad existente.

El modelo, como vemos en la Figura 1, se estructura en forma de árbol compuesto de una sucesión de nodos y ramas que constituyen, respectivamente, los grupos y divisiones que se van

⁹ Ver Novak y LaDue (1999), Thomas (2000), Carson y Hoyt (2000), Bonilla et al (2002), Moisen y Frescino (2002), Bose (2003)

Figura 1
Arboles de Decisión



realizando de la muestra original. Cada uno de los nodos terminales representa aquel grupo cuyo coste esperado de error sea menor, es decir, aquellos que presenten menor riesgo. El riesgo total del árbol se calcula sumando los correspondientes a cada uno de los nodos terminales.

En definitiva, el algoritmo de partición recursiva puede resumirse en los siguientes cuatro pasos:

- 1.- Estudiar todas y cada una de las variables explicativas con objeto de determinar para cuál de ellas y para qué valor es posible incrementar la homogeneidad de los subgrupos. Existen diversos criterios que permiten seleccionar la mejor división de cada nodo, todos ellos buscan siempre aquella división que reduzca la función de pérdida que, en el caso de los *Arboles de Regresión*, se determina mediante el error cuadrático medio (ECM). El algoritmo optará por aquella división que mejore el resultado, mejora que se mide comparando la que presenta el nodo de procedencia con el correspondiente a las dos regiones obtenidas en la partición.
- 2.- El paso anterior se repite hasta que, o bien resulte imposible mejorar la situación realizando otra división, o bien el nodo obtenido presente el tamaño mínimo. En esta fase del algoritmo se obtiene el árbol máximo en el cual cada uno de sus nodos interiores es una división del eje de características.

Ahora bien, este procedimiento, tal y como ha sido expuesto, presenta un grave problema, el *sobreaprendizaje*: el modelo memoriza las observaciones de la muestra siendo incapaz de extraer las características más importantes, lo que le impedirá "generalizar adecuadamente", obteniendo resultados erróneos en los casos no contemplados con anterioridad. Para evitarlo

Friedman (1977) propuso la siguiente solución: desarrollar el árbol al máximo, y posteriormente ir *podándolo* eliminando las divisiones y, por lo tanto, los nodos que presenten un mayor coste de complejidad, hasta encontrar el tamaño óptimo, que será aquel que minimice el coste de complejidad.

- 3.- Calcular la complejidad de todos y cada uno de los subárboles *podando* aquellos que verifiquen la siguiente expresión,

$$R_K(T_1) = \min_{T' \leq T} R_K(T') \tag{4}$$

siendo el coste de complejidad,

$$R_K(T) = [R(T) + K * |T|] \tag{5}$$

donde, $R_K(T)$: coste de complejidad del árbol T para un determinado valor del parámetro K

$R(T)$: riesgo de errar (K se denomina parámetro de complejidad que penaliza la complejidad del árbol y siempre será positivo)

$|T|$: número de nodos terminales.

- 4.- Encontrar todos los valores críticos de K , y utilizar la técnica de *validación cruzada* para cada uno de ellos con objeto de estimar $R(T(K))$, eligiendo aquella estructura que presente mejor valor estimado de $R(T(K))$.

Por tanto, el principal problema con el que se enfrenta este modelo es la complejidad de su estructura que, como ya hemos indicado, fácilmente puede desembocar en el *sobreaprendizaje* del modelo. De ahí que no sólo se persiga crear conjuntos homogéneos con bajo riesgo, sino también obtener aquella estructura que presente una complejidad óptima. Bajo este doble objetivo, resulta necesario penalizar la excesiva complejidad del árbol.

3.2. Splines de Regresión Adaptativa Multivariante (MARS)

Los *Splines de Regresión Adaptativa Multivariante*, MARS (Friedman, 1991) consisten en un algoritmo basado en las ideas de particionamiento recursivo (Morgan y Sonquist, 1963) y regresión multietapa que emplea funciones tipo *spline* para lograr la aproximación a una función de regresión arbitraria. El procedimiento consiste en particionar el dominio de definición de la función en diferentes regiones, ajustando en cada una de ellas una función tipo *spline*.

Un *spline* cúbico univariante con umbrales k_1, k_2, \dots, k_s es un *polinomio* cúbico definido sobre los intervalos $(-\infty, k_1), (k_1, k_2), \dots, (k_s, \infty)$, cuya segunda derivada es continua en todos los puntos. Fijados los umbrales, las funciones $1, x, x^2, x^3, (x-k_1)^3+, \dots, (x-k_s)^3+$, donde $(x-k_j)^3+$ es la parte positiva de $(x-k_j)^3$, constituyen una base del espacio vectorial de todas las funciones *spline* cúbicas, a estas funciones se les denomina *funciones base*.

Los *splines* cúbicos multivariantes también forman un espacio vectorial. En n dimensiones, cada función base es el producto de n funciones base univariantes, una para cada coordenada, es decir, un *spline* multivariante tiene la siguiente forma,

$$B(x) = B(x_1, x_2, \dots, x_n) = \prod_{v=1}^n B_v(x_v) \quad (6)$$

donde B_v es una función base univariante para la v -ésima coordenada. Un *spline* multivariante incluye, por tanto, todas las posibles interacciones que se producen entre las variables introduciendo productos cruzados de las funciones *spline* univariantes.

Dado el modelo de regresión:

$$y_j = g(x_{j1}, x_{j2}, \dots, x_{jn}) + \varepsilon_j \quad j = 1, 2, \dots, N \quad (7)$$

donde, n : número de atributos

N : número de casos

G : función de clasificación desconocida

ε_j : término de error con media cero

El procedimiento empleado por el modelo MARS para estimar g puede resumirse en tres etapas. En primer lugar, se emplea un algoritmo "hacia adelante" para seleccionar las funciones base y los puntos de truncado. Seguidamente, se emplea un algoritmo "hacia atrás" para eliminar funciones base, hasta que se encuentra el mejor conjunto de las mismas. El propósito de esta fase consiste en reducir el grado de complejidad del modelo, aumentando su capacidad de generalización. Finalmente se utiliza un suavizado que proporciona a la aproximación obtenida el grado de continuidad deseable en las fronteras de las particiones. Se trata de un procedimiento adaptativo en el sentido de que la selección de las funciones base es guiada por los datos y , por tanto, específica al problema en cuestión. Puesto que sólo un número reducido de funciones base son empleadas, este procedimiento permite reducir significativamente la alta dimensionalidad inherente a algunos problemas.

El procedimiento hacia adelante comienza con una función constante, $B_0(x) = 1$. Seguidamente se van añadiendo funciones univariantes en la forma de funciones lineales truncadas $(x-k)^+$, $(x-k)^-$. Las funciones base que recogen las interacciones son creadas multiplicando una función base existente por una función lineal truncada que involucre otra variable. Tanto la función base originaria como las nuevas creadas son empleadas (a diferencia de otros algoritmos de particionamiento recursivo, que utilizan sólo la nueva función obtenida a partir de la anterior). Una vez que $M-1$ funciones base han sido elegidas, la M -ésima función base es seleccionada de entre las que pueden crearse a partir de las $M-1$ anteriores de manera que minimice un criterio de pérdida cuadrática:

$$P(\hat{g}_M) = \frac{1}{N} \sum_{j=1}^N [y_j - \hat{g}_M(x_j)]^2 \quad (8)$$

El algoritmo se detiene cuando la aproximación construida incluye un número máximo de funciones fijadas por el usuario.

La aproximación final proporcionada por MARS tiene la forma,

$$\hat{g}_M(x) = a_0 + \sum_{m=1}^M a_m \left\{ \prod_{l=1}^{L_m} [s_{l,m}(x_{v(l,m)} - k_{l,m})]_{\pm} \right\} \quad (9)$$

donde, M : número de funciones base linealmente independientes
 L_m : número de divisiones o funciones lineales truncadas multiplicadas en la m -ésima función base
 a_m : coeficiente de la m -ésima función base
 $x_{v(l,m)}$: variable predictora correspondiente a la l -ésima función lineal truncada en la m -ésima función base
 $k_{l,m}$: el umbral correspondiente a $x_{v(l,m)}$ y $s_{l,m}$ es +1 o -1.

$$\left\{ \prod_{l=1}^{L_m} [s_{l,m} (x_{v(l,m)} - k_{l,m})]_+ \right\} : m\text{-ésima función base}$$

Es habitual restringir el grado máximo de interacción a tres, $L_m=3$, mientras que el número de umbrales es automáticamente seleccionado por MARS, dividiendo el rango de definición de cada una de las variables en subintervalos.

En el procedimiento hacia atrás, MARS emplea una versión modificada del criterio de validación cruzada generalizada de Craven y Wahba (1979), dado por la expresión:

$$CVG(M) = \frac{\frac{1}{N} \sum_{i=1}^N [y_i - \hat{f}_M(x_i)]^2}{\{1 - [C(M) *] / N\}^2} \quad (10)$$

donde $C(M)$ es un término que penaliza la complejidad del modelo, por ejemplo, medida por el número de funciones base (es decir $C(M)=M$). Según este criterio, un modelo más sencillo puede ser preferido frente a otro más complejo aunque aquél muestre un peor ajuste, en el caso de que el número de parámetros sea significativamente menor.

Finalmente, y puesto que la aproximación mediante *splines* lineales produce discontinuidades en las derivadas en las fronteras de los subintervalos (k_s, k_{s+1}) , MARS emplea un suavizado consistente en reemplazar las funciones base truncadas lineales por funciones cúbicas que coincidan con la aproximación lineal por tramos en los extremos de los subintervalos. Este suavizado asegura la continuidad de la primera y segunda derivada de la aproximación en todos los puntos excepto en los extremos del intervalo.

La flexibilidad del modelo MARS queda determinada por dos parámetros: el número de funciones base y el grado de interacción entre las variables. La determinación del modelo óptimo consistirá, por tanto, en establecer cual de las combinaciones de ambos parámetros proporciona menores errores de validación cruzada, cuestión que veremos en la sección siguiente.

3.3 Problema del Sobreaprendizaje: Método de Validación Cruzada.

Como hemos podido comprobar en la sección anterior, el problema que presentan los algoritmos que van a ser utilizados, y además común al resto de los métodos no paramétricos, es el *sobreaprendizaje*. La aparición de este fenómeno puede atribuirse fundamentalmente a dos causas:

1. La sobreparametrización, el modelo presenta una estructura más compleja de la necesaria para tratar el problema en cuestión.

-
2. La escasez de datos que impide al modelo extraer en la fase de entrenamiento las características más relevantes de la muestra y, posteriormente, en la fase de test, verificar la capacidad predictiva del modelo con otra muestra de datos distinta a la utilizada en el entrenamiento.

Con objeto de evitar el sobreaprendizaje se viene utilizando, entre otros¹⁰, el método de *validación cruzada* propuesto por Stone (1974) que, como veremos cuando presentemos los resultados, hemos empleado para elegir la estructura idónea de los *Arboles de Regresión* y de los *Splines de Regresión Adaptativa Multivariante*. El proceso se estructura en los siguientes pasos:

1. Las observaciones que componen la muestra se dividen en dos: un conjunto de entrenamiento, que sirve para ajustar el modelo, y un conjunto de test que es empleado para validarlo.
2. El conjunto de entrenamiento se divide aleatoriamente en 10 particiones distintas.
3. Por rotación, un conjunto de 9 particiones se utiliza para estimar el modelo con un número de parámetros determinado, y la décima partición para contrastar su capacidad predictiva.
4. El paso 2 se repite diez veces, de forma que el algoritmo, utilizando distintas estructuras, va a ser entrenado y testeado con 10 pares distintos de conjuntos de entrenamiento y test, siendo la estructura óptima aquella que minimice el error de predicción a lo largo de los 10 conjuntos de test (a este error se le denomina error de validación cruzada, EVC).
5. Elegida la estructura óptima, se utilizará toda la muestra para reentrenar el modelo, de manera que se entrenará y testará con los conjuntos totales para obtener el error de predicción (EP). Puesto que el EVC es un estimador insesgado del error de predicción del modelo elegido (EP) (Stone, 1974), el modelo seleccionado tendrá también una capacidad de generalización óptima cuando sea empleado con observaciones no presentes en el conjunto de entrenamiento.

En concreto, y a modo de ejemplo, en nuestro análisis, en uno de los sectores analizados, disponemos de una muestra de 538 observaciones, de las cuales 165 hemos reservado, como conjunto de test, con objeto de testar la capacidad generalizadora del modelo (EP), y las otras 373 observaciones se han utilizado como conjunto de entrenamiento para elegir aquel modelo cuya estructura presente menor EVC. Tales submuestras no se corresponden con ningún criterio *ad hoc*, pero están en línea con la literatura al respecto.

Las 373 observaciones destinadas al entrenamiento se han dividido a su vez en conjuntos de entrenamiento y test, representando el conjunto de test el 10% de la muestra (37 observaciones). Las observaciones de estas dos submuestras se han combinado de tal forma que disponemos de 10 pares no solapados de conjuntos de entrenamiento y test formados por 336 y 37 observaciones respectivamente, que se utilizarán en la obtención del EVC.

De manera que, los algoritmos utilizados han sido entrenados y testeados con estos 10 pares de conjuntos utilizando distintas estructuras, para, de este modo, poder determinar su estructura óptima. Dicha estructura será aquella que, como hemos indicado anteriormente, presente menor EVC, calculado éste como una media de los errores cometidos a lo largo de los 10 conjuntos de

10 Existen diferentes alternativas, ver por ejemplo Olmeda y Barbe-Romero (1993)

test validados. El parámetro que determina la complejidad de los *Arboles de Regresión* es el número de nodos, por lo que la selección de su estructura óptima consiste en determinar el número óptimo de nodos. Mientras que en el MARS la complejidad viene determinada por el número de funciones base.

Para finalizar, el modelo elegido será entrenado y testeado con la muestra total (373 observaciones de entrenamiento y 165 de test) con objeto de obtener el EP que nos permitirá comparar la potencia predictiva del algoritmo en cada uno de los sectores analizados.

4. RESULTADOS

Los *Arboles de Regresión* y los *Splines de Regresión Adaptativa Multivariante*, descritos en la sección 3, se han utilizado en la predicción del *spread* de las emisiones de eurobonos realizadas durante el periodo 1995-1999. Los modelos no paramétricos requieren, en primer lugar, encontrar la parametrización más adecuada para, de este modo, evitar el problema del *sobreaprendizaje* característico de casi todas estas técnicas.

Como hemos mencionado, empleamos el procedimiento de *validación cruzada* propuesto por Stone (1974) para eludir los daños causados por la sobreparametrización, y poder obtener generalizaciones eficientes. El parámetro que determina la complejidad del modelo CART utilizado en nuestro análisis es el número de nodos, mientras que en el caso del MARS sería el número de funciones base.

Para ambos algoritmos, ha sido necesario dividir las observaciones de cada uno de los sectores analizados en dos conjuntos de entrenamiento y test, reservando el de test para obtener el EP. La submuestra de entrenamiento se ha combinado formando 10 pares no solapados de entrenamiento y test, con objeto de calcular el EVC que nos determinará la estructura óptima del modelo. Las tablas de EVC han sido calculadas para cada sector en que se divide la muestra, permitiéndonos obtener el EP que determinará la precisión del modelo.

El procedimiento seguido en la determinación de la estructura óptima y, de este modo, poder evitar el problema del *sobreaprendizaje* es el siguiente. En primer lugar, hemos obtenido el EVC. En el caso del CART, inicialmente, el error ha sido calculado sin realizar ninguna *poda* y, posteriormente, hemos ido simplificando la estructura *podando* aquellas ramas que presenten un mayor coste de complejidad. Utilizando distintos valores de k , y para cada uno de los sectores analizados, hemos comprobado que el *sobreaprendizaje* no resulta significativo, aunque no por ello la técnica de *validación cruzada* ha dejado de ser relevante en la determinación de la estructura óptima. Este proceso se ha repetido para el MARS, utilizando distinto número de funciones base¹¹.

Elegida la estructura óptima y, con objeto de determinar la precisión de los modelos sobre cada uno de los sectores, se ha calculado el EP (utilizamos el error cuadrático medio, ECM, por ser más coherente con las metodologías utilizadas).

Igualmente, se ha realizado un análisis comparativo entre los resultados obtenidos por estos dos métodos no paramétricos y, la regresión lineal estimada por MCO. Además, con la intención

11 Ver tablas de los EVC y EP en el Anexo.

de evitar que la división de la muestra pudiera afectar a los resultados obtenidos por MCO se han realizado diez particiones aleatorias de entrenamiento y test, respetando las proporciones de las muestras utilizadas en el CART y el MARS. De forma que el EP de la estimación por MCO será la media de los errores cometidos a lo largo de estos conjuntos.

En la Tabla 3 se muestran los EP por sectores, observando que el CART presenta una mayor exactitud en la predicción del *spread* de las emisiones de los soberanos y de los bancos (0,0751 y 0,0940 respectivamente). Mientras que su comportamiento en las emisiones realizadas por los otros dos sectores es menos preciso. Destacando el ECM cometido en las emisiones de las empresas, que nos permite afirmar que este modelo no resulta idóneo para este tipo de emisores.

El MARS al igual que la estimación por MCO presenta mayor precisión en las emisiones realizadas por los bancos (0,0686 y 0,0674 respectivamente). En los demás sectores el comportamiento de ambos métodos no resulta tan potente. Al igual que ocurría con el algoritmo CART, el *spread* de las emisiones del sector empresas sería difícilmente predecible con la aplicación de estas técnicas.

Tabla 3
Errores de predicción CART, MARS y estimación MCO: ECM

	CART		MARS		Estimación MCO	
	Entrenamiento	Test	Entrenamiento	Test	Entrenamiento	Test
Bancos	0,0662	0,0940	0,0924	0,0686	0,0919	0,0674
Empresas	0,8343	2,0060	1,2133	1,6390	1,3853	1,2084
Serv. Financieros	0,5188	0,2045	0,6871	0,1489	0,5127	0,4207
Estado	0,2230	0,0751	0,5707	0,3574	0,5415	0,5407

Nota: Los valores del ECM están multiplicados por 10²

Desde un punto de vista teórico, los resultados son coherentes con la literatura del mercado de eurobonos debido a que los bancos presentan una considerable estabilidad financiera motivada, en gran parte, por el hecho de que pertenecen a países desarrollados (EEUU, Alemania, Francia, etc.) y que, indirectamente, se refleja en las emisiones de sus activos. Por ello, con los algoritmos CART, MARS y la estimación por MCO se obtiene menor error en dicho sector. Mientras que la débil precisión de los modelos en la predicción del *spread* de las emisiones de las empresas refleja indirectamente el comportamiento más heterogéneo de este sector.

En la construcción de la muestra se impuso la condición de que todos los emisores hubiesen emitido al menos una vez al año, en cada uno de los años del periodo analizado. Esto supuso que tuviéramos evidencia empírica de que son las empresas el sector más inestable respecto a la frecuencia de emisión en el mercado, ya que tuvieron que ser eliminados un número considerable de emisores que no cumplían dicho requisito. Así, podemos comprobar que esta inestabilidad ha influido indirectamente en la predicción de su *spread*.

Una vez obtenida la estructura óptima se ha calculado el error absoluto medio (EAM) con objeto de determinar cual sería la probabilidad de que el modelo cometiera un error superior al EAM en sus estimaciones.

Tabla 4
Errores de predicción del CART: EAM

	CART		Probabilidades	
	Entrenamiento	Test	Entrenamiento	Test
Bancos	0,0098	0,0108	24,62%	23,47%
Empresas	0,0316	0,0351	17,57%	14,56%
Serv.Financieros	0,0303	0,0212	13,01%	20,96%
Estado	0,0173	0,0109	17,69%	17,57%

Tabla 5
Errores de predicción del MARS: EAM

	MARS		Probabilidades	
	Entrenamiento	Test	Entrenamiento	Test
Bancos	0,0108	0,0106	27,79%	31,67%
Empresas	0,0439	0,0379	28,87%	25,24%
Serv.Financieros	0,0332	0,0255	15,75%	37,10%
Estado	0,0403	0,0372	30,83%	38,79%

Tabla 6
Errores de predicción de la estimación por MCO: EAM

	Estimación MCO		Probabilidades	
	Entrenamiento	Test	Entrenamiento	Test
Bancos	0,0110	0,0100	28,16%	29,14%
Empresas	0,0448	0,0414	21,88%	26,31%
Serv.Financieros	0,0301	0,0270	27,24%	29,95%
Estado	0,0450	0,0466	26,76%	26,55%

Según los resultados que mostramos en la Tabla 4, con el algoritmo CART la probabilidad de cometer un error superior a su correspondiente EAM es menor en el sector empresas y Estado que en los bancos y servicios financieros (14,56% y 17,57% frente a 23,47% y 20,97%). Sin embargo, comparando los resultados del EAM con la mediana del *spread* en cada sector, comprobamos que el EAM de los soberanos y los bancos está muy por debajo del valor de su mediana. De manera que el error cometido en estos sectores no resulta significativo dado que los valores de sus *spreads* son bastante más elevados.

Esta evidencia nos refuerza los resultados obtenidos en la Tabla 3, y nos indica que el modelo resulta más preciso en la predicción del *spread* de las emisiones de los soberanos, ya que la probabilidad de cometer un error superior al EAM es menor que en el caso de los bancos.

Por otra parte, en las Tablas 5 y 6 observamos que el comportamiento del algoritmo MARS y de la estimación por MCO difiere de los *Arboles de Regresión* en algunos sectores. En el caso de las emisiones de las empresas ninguno de los tres métodos ha resultado apropiado para predecir su *spread*. Aplicando el MARS y la estimación por MCO obtenemos una probabilidad menor que en el resto de sectores pero, al igual que ocurría con el otro algoritmo, su EAM es muy superior al valor de su mediana. Igualmente, cabría destacar que tanto los métodos no paramétricos como el paramétrico han resultado muy potentes en las emisiones de los bancos, llegando a un EAM muy inferior al valor de su mediana.

Sin embargo, existen discrepancias en cuanto a los soberanos y a los servicios financieros. Realizando el mismo razonamiento, observamos que el comportamiento del MARS y la estimación por MCO en la predicción del *spread* de las emisiones de los soberanos no es adecuado, mientras que sí lo es en los servicios financieros. Estos resultados no son del todo coherentes con la literatura ya que los soberanos presentan una mayor solvencia y estabilidad financiera que debería reflejarse en la potencia del algoritmo, al igual que ocurre en el sector bancos.

5. CONCLUSIONES

En este trabajo hemos comprobado el buen comportamiento, en términos de predicción, de dos métodos no paramétricos, los *Arboles de Regresión* y los *Splines de Regresión Adaptativa Multivariante*, y de uno paramétrico, la estimación por MCO, en el contexto del mercado de eurobonos y, en concreto, en el sector bancos. Además, el procedimiento que con más frecuencia se utiliza para la identificación de modelos no paramétricos, la *validación cruzada*, nos ha permitido obtener la estructura óptima de dichos algoritmos en cada uno de los sectores analizados. Sin embargo, el EVC no ha resultado ser un buen estimador del EP, tal y como establece la literatura.

En primer lugar, obtenemos el EVC para un *Arbol de Regresión* sin realizar ninguna *poda* y, posteriormente, hemos ido simplificando la estructura *podando* aquellas ramas que presenten un mayor coste de complejidad. Utilizando distintos valores de k comprobamos que, para la muestra utilizada, el sobreaprendizaje no resulta significativo, por lo que la *validación cruzada* ha sido relevante en la determinación de la estructura óptima. Igualmente se obtuvo la estructura óptima del MARS utilizando distinto número de funciones base.

El CART aplicado sobre la muestra de emisiones de eurobonos pertenecientes a los soberanos y los bancos ha resultado ser más preciso que en el caso de las empresas y los servicios financieros. Además, en los soberanos la probabilidad de cometer un error superior a su EAM es menor que en los bancos, lo que refleja que el modelo resulta más potente en la predicción del *spread* de las emisiones del sector Estado.

Los resultados obtenidos son coherentes con la literatura del mercado de eurobonos, ya que las emisiones de los Estados junto con las de los bancos presentan una mayor estabilidad en sus variables financieras y macroeconómicas. Sin embargo, tanto el MARS como la estimación por

MCO han resultado más potentes en la predicción del *spread* de los bancos y los servicios financieros, no resultando apropiado en el caso de los soberanos y las empresas.

Todo ello nos permite argumentar cierta superioridad del algoritmo CART frente al MARS y a la estimación por MCO en cuanto a su capacidad predictiva. Desde esta perspectiva, nuestro trabajo evidencia una mayor fiabilidad en relación con los *spread* de bancos y soberanos, en oposición a los servicios financieros y, sobretodo, empresas.

Por otro lado, una aportación relevante de este trabajo viene dada por la aplicación de estas técnicas para un mejor conocimiento de la predicción de los *spreads* en las emisiones de bonos internacionales, dado que la literatura se centra, habitualmente, en modelos paramétricos para estimar el papel de las diferentes variables.

ANEXO

Tabla 1
Modelo CART: EVC y EP del sector bancos

ESTRUCTURAS DEL MODELO								
Conj.	Sin poda		k=0,001		k=0,002		k=0,003	
	Entren	Test	Entren	Test	Entren	Test	Entren	Test
1	0,0772	0,0275	0,0773	0,0264	0,0777	0,0231	0,0787	0,0229
2	0,0780	0,1267	0,0780	0,1127	0,0789	0,1190	0,0798	0,1173
3	0,0299	1,0430	0,0304	0,8343	0,0327	0,6707	0,0332	0,6580
4	0,0579	0,2179	0,0582	0,1984	0,0602	0,1918	0,0602	0,1847
5	0,0778	0,0774	0,0779	0,0745	0,0784	0,0683	0,0788	0,0667
6	0,0725	0,0179	0,0726	0,0168	0,0734	0,0146	0,0743	0,0131
7	0,0833	0,0762	0,0833	0,0734	0,0844	0,0609	0,0853	0,0590
8	0,0703	0,0452	0,0704	0,0438	0,0711	0,0400	0,0724	0,0384
9	0,0763	0,0546	0,0764	0,0521	0,07661	0,0514	0,07855	0,0445
10	0,0806	0,0065	0,0807	0,0063	0,0809	0,0639	0,0822	0,0822
E.V.C.	0,0704	0,1693	0,0705	0,1439	0,0714	0,1304	0,0723	0,1287
E.PRED							0,0662	0,0940

Nota: Todos los resultados están multiplicados por 10^2 . Probamos con valores $k > 0,003$ y la estructura resultaba demasiado sencilla, y con $k < 0,001$ y aportaba ninguna mejora en los resultados.

Tabla 2
Modelo CART: EVC y EP del sector empresas

Conj.		Sin poda		k=0,001		k=0,005		k=0,007		k=0,01		k=0,05	
		Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test
1	0,7774	2,1530	0,7742	1,9720	0,7750	1,8180	0,7750	1,8180	0,7775	1,5450	0,8410	1,5420	
2	0,8143	0,7427	0,8109	0,6677	0,8079	0,5899	0,8079	0,5899	0,8835	0,5270	0,8835	0,5270	
3	0,9470	2,8330	0,9461	2,6440	0,9461	2,6440	0,9461	2,6440	0,9499	2,4580	0,9834	2,3130	
4	0,8042	4,4160	0,7997	3,6810	0,7992	3,4070	0,7992	3,4070	0,8482	3,1340	0,8482	3,1340	
5	0,8598	0,7545	0,8565	0,6921	0,8560	0,6444	0,8560	0,6444	0,8609	0,7590	0,9170	0,4590	
6	0,3316	18,0800	0,3271	11,6200	0,3301	10,8500	0,3301	10,8500	0,3336	10,070	0,4159	8,5460	
7	0,8266	0,3879	0,8264	0,3627	0,8264	0,3627	0,8264	0,3627	0,9043	0,2689	0,9043	0,2689	
8	0,8310	0,6655	0,8305	0,6226	0,8305	0,6226	0,8305	0,6226	0,8422	0,4793	0,9179	0,4410	
9	0,8282	0,6531	0,8233	0,5473	0,82320	0,5073	0,82320	0,5073	0,8625	0,8051	0,9899	0,7329	
10	0,8362	0,6303	0,8370	0,5764	0,8370	0,5764	0,8370	0,5764	0,8370	0,5764	0,5764	0,4712	
E.V.C.	0,7856	3,1316	0,7832	2,3386	0,7831	2,2022	0,7831	2,2022	0,8100	2,0623	0,8278	1,8435	
										E.PRED	0,8343	2,0060	

Nota: Todos los resultados están multiplicados por 10^2 . Probamos con valores $k > 0,05$ y la estructura resultaba demasiado sencilla, y con $k < 0,001$ y no aportaba ninguna mejora en los resultados, al igual que los valores intermedios $k = 0,002, 0,003, 0,004, 0,006, 0,008, 0,009, 0,02, 0,03, 0,04$.

Tabla 3
Modelo CART: EVC y EP del sector servicios financieros

ESTRUCTURAS DEL MODELO											
Conj.	Sin poda		k=0,001		k=0,003		k=0,005		k=0,007		
	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test	
1	0,3494	29,7300	0,3475	14,8600	0,3428	3,6890	0,3692	2,6390	0,3692	2,6390	
2	0,5595	0,6589	0,5494	0,2532	0,5731	0,0241	0,5731	0,0241	0,5731	0,0241	
3	0,5350	5,7630	0,5224	1,2280	0,5166	0,8231	0,5200	0,6508	0,5200	0,6508	
4	0,5556	1,7320	0,5461	0,6940	0,5593	0,6447	0,5593	0,6447	0,5593	0,6447	
5	0,5978	2,8010	0,5942	2,1460	0,6016	0,7656	0,6016	0,7656	0,6016	0,7656	
6	0,5828	1,6210	0,5772	1,1240	0,5772	1,1240	0,5762	0,9759	0,5990	0,6937	
7	0,3675	45,2400	0,3608	9,1260	0,3709	4,0540	0,3709	4,0540	0,3709	4,0540	
8	0,5594	Inf	0,5454	0,6994	0,5378	0,2933	0,5616	0,1727	0,5616	0,1727	
9	0,5237	8,0320	0,5145	2,0100	0,5097	1,1170	0,51120	0,9938	0,52560	0,6648	
10	0,5179	1,5010	0,5150	1,1850	0,5103	0,7292	0,5103	0,7292	0,5364	0,5228	
E.V.C.	0,5149	Inf	0,5073	3,3326	0,5099	1,3264	0,5153	1,1650	0,5217	1,0832	
									E.PRED	0,5188	0,2045

Nota: Todos los resultados están multiplicados por 10^2 . Probamos con valores $k > 0,007$ y la estructura resultaba demasiado sencilla, y con $k < 0,001$ y no aportaba ninguna mejora en los resultados, al igual que los valores intermedios $k = 0,002, 0,004, 0,006$.

Tabla 4
Modelo CART: EVC y EP del sector Estado

ESTRUCTURAS DEL MODELO														
nj.	Sin poda		k=0,001		k=0,005		k=0,007		K0,01		k=0,05		k=0,1	
	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test
1	0,2220	0,0842	0,2220	0,0652	0,2301	0,0490	0,2301	0,0490	0,2301	0,0490	0,3609	0,2845	0,4290	0,2975
2	0,1809	1,5090	0,1807	1,4460	0,1860	1,3140	0,1860	1,3140	0,1926	1,2640	0,2258	1,199	0,3850	1,3960
3	0,2462	0,4397	0,2463	0,4147	0,2510	0,3770	0,2510	0,3770	0,2510	0,3770	0,2885	0,3371	0,5159	0,1324
4	0,2717	0,2903	0,2712	0,2883	0,2760	0,2925	0,2760	0,2925	0,2760	0,2925	0,3062	0,3235	0,4768	0,5070
5	0,2398	0,0302	0,2400	0,0304	0,2467	0,0217	0,2467	0,0217	0,2467	0,0217	0,2850	0,0543	0,4082	0,0675
6	0,2483	0,0894	0,2480	0,0857	0,2554	0,0359	0,2554	0,0359	0,2554	0,0359	0,2938	0,0986	0,4459	0,1304
7	0,2685	0,3530	0,2681	0,3362	0,2711	0,2789	0,2742	0,2485	0,2832	0,2397	0,3178	0,3446	0,5084	0,2101
8	0,1931	1,8110	0,1933	1,7260	0,1953	1,5630	0,2029	1,7110	0,2029	1,7110	0,2603	1,6320	0,3669	1,5700
9	0,2232	0,0126	0,2236	0,01200	0,22950	0,0108	0,22950	0,0108	0,2338	0,0096	0,2639	0,0511	0,4494	0,0954
10	0,2180	0,4548	0,2191	0,4367	0,2191	0,4367	0,2247	0,4531	0,2498	0,4654	0,2498	0,4654	0,4041	0,5434
v.C.	0,2312	0,5074	0,2312	0,4841	0,2360	0,4379	0,2377	0,4513	0,2422	0,4466	0,2852	0,4790	0,4390	0,4950
											E.PRED	0,2230	0,0751	

Nota: Todos los resultados están multiplicados por 10^2 . Probamos con valores $k > 0,1$ y la estructura resultaba demasiado sencilla, y con $k < 0,001$ y no aportaba ninguna mejora en los resultados, al igual que los valores intermedios $k = 0,002, 0,003, 0,004, 0,006, 0,008, 0,009, 0,02, 0,03, 0,04, 0,06, 0,07, 0,08, 0,09$.

Tabla 5
Modelo MARX: EVC y EP del sector bancos

ESTRUCTURAS DEL MODELO												
Nº f.base	4		6		8		12		16		20	
Conj.	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test
1	0,1025	0,0127	0,1014	0,0116	0,1002	0,0135	0,0978	0,0168	0,0962	0,0159	0,0962	0,0165
2	0,0935	0,0933	0,0935	0,0933	0,0935	0,0933	0,0927	0,0906	0,0886	0,1003	0,0886	0,1003
3	0,0400	0,5791	0,0399	0,5805	0,0399	0,5805	0,0395	0,5810	0,0394	0,5783	0,0377	0,5851
4	0,0843	0,1662	0,0843	0,1662	0,0836	0,1642	0,0811	0,1665	0,0811	0,1665	0,0811	0,1665
5	0,1013	0,0123	0,1013	0,0123	0,1002	0,0138	0,1002	0,0138	0,1002	0,0015	0,1002	0,0138
6	0,1019	0,0072	0,1019	0,0072	0,1009	0,0073	0,0987	0,0075	0,0970	0,0085	0,0997	0,0072
7	0,1008	0,0170	0,1008	0,0170	0,0998	0,0175	0,0974	0,0195	0,0974	0,0195	0,1006	0,0186
8	0,0977	0,0451	0,0977	0,0451	0,0977	0,0451	0,0977	0,0451	0,0965	0,0477	0,0965	0,0477
9	0,1015	0,0108	0,1015	0,0051	0,1003	0,0128	0,1003	0,0128	0,1002	0,0128	0,1012	0,0129
10	0,1018	0,0079	0,1018	0,0079	0,1006	0,0079	0,1006	0,0079	0,0995	0,0072	0,0995	0,0072
E.V.C.	0,0925	0,0952	0,0924	0,0946	0,0917	0,0956	0,0906	0,0961	0,0896	0,0958	0,0901	0,0976
E.PRED 0,0924 0,0686												

Nota: Todos los resultados están multiplicados por 10^2 . Probamos con distinto número de funciones base y no aportaba ninguna mejora en los resultados

Tabla 6
Modelo MARX: EVC y EP del sector empresas

ESTRUCTURAS DEL MODELO												
Nº f.base	4		8		12		16		20		24	
Conj.	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test
1	1,3244	0,2406	1,3312	0,2368	1,3171	0,2474	1,2894	0,2726	1,2894	0,2726	1,2894	0,2726
2	1,3125	0,3476	1,3116	0,4383	1,2973	0,4409	1,2748	0,4068	1,2748	0,4068	1,2564	0,4392
3	1,2247	1,1745	1,2217	1,2965	1,2094	1,2745	1,1780	1,3435	1,1780	1,3435	1,1780	1,3435
4	1,0782	3,1478	1,0607	2,8912	1,0324	2,8756	1,0324	2,8756	1,0324	2,8756	1,0324	2,8756
5	1,3332	0,1680	1,3451	0,1216	1,3318	0,1143	1,3318	0,1143	1,3072	2,7294	1,3072	0,1187
6	0,6249	6,8548	0,5525	7,0385	0,5884	7,0335	0,5532	7,1205	0,5693	7,3288	0,5693	7,3288
7	1,3154	0,3274	1,3268	0,2884	1,3140	0,2757	1,3140	0,4450	1,3140	0,2757	1,3140	0,2757
8	1,3401	0,0905	1,3500	0,0678	1,3353	0,0745	1,3353	0,0745	1,3060	0,1287	1,3060	0,1287
9	1,2717	0,7277	1,2780	0,7421	1,2671	0,7124	1,2419	0,7189	1,2419	0,7189	1,2419	0,7189
10	1,3385	0,1085	1,3458	0,1109	1,3318	0,1098	1,3318	0,1098	1,3015	0,1653	1,3015	0,1653
E.V.C.	1,2164	1,3187	1,2123	1,3232	1,2025	1,3158	1,1883	1,3481	1,1815	1,6245	1,1796	1,3667
E.PRED 1,2133 1,6390												

Nota: Todos los resultados están multiplicados por 10^2 . Probamos con distinto número de funciones base y no aportaba ninguna mejora en los resultados

Tabla 7
Modelo MARX: EVC y EP del sector servicios financieros

ESTRUCTURAS DEL MODELO													
Nº f.base	4		8		12		16		20		24		
Conj.	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test	
1	0,4106	2,8613	0,4289	3,1056	0,3698	3,1915	0,3698	3,1915	0,4289	3,1056	0,4289	3,1056	
2	0,7024	0,0511	0,7024	0,7155	0,7554	0,0460	0,7554	0,0460	0,7554	0,0460	0,7554	0,0460	
3	0,6451	0,5156	0,6516	0,0511	0,6516	7,4220	0,6516	0,5301	0,6516	0,5301	0,7084	0,4864	
4	0,6883	0,1838	0,6883	2,5731	0,7442	0,1492	0,7442	0,1492	0,7442	0,7442	0,7442	0,1492	
5	0,6999	0,0732	0,6999	0,0732	0,6999	0,0732	0,7479	0,1152	0,7479	0,1152	0,7479	0,1152	
6	0,6902	0,1490	0,6902	2,0858	0,6902	0,1490	0,6902	0,1490	0,7485	0,1103	0,7485	0,1103	
7	0,4305	2,7010	0,4305	2,7010	0,4502	2,9375	0,4502	2,9375	0,4502	2,9375	0,4502	2,9375	
8	0,6946	0,1236	0,6946	0,1236	0,6946	0,1236	0,6946	0,1236	0,7464	0,1280	0,7464	0,1280	
9	0,2020	2,8283	0,6862	0,2020	0,6862	0,2020	0,7521	0,0743	0,7521	0,8008	0,7521	0,0743	
10	0,6956	1,7125	0,6956	1,7125	0,7535	0,0639	0,0743	1,7125	0,7535	0,0639	0,7179	0,1343	
E.V.C.	0,5859	1,1199	0,6368	1,3343	0,6496	1,4358	0,5930	0,9029	0,6779	0,8582	0,6800	0,7287	
											E.PRED.	0,6871	0,1489

Nota: Todos los resultados están multiplicados por 10^2 . Probamos con distinto número de funciones base y no aportaba ninguna mejora en los resultados

Tabla 8
Modelo MARX: EVC y EP del sector Estado

ESTRUCTURAS DEL MODELO										
Nº f.base	1		2		4		8		12	
Conj.	Entren	Test	Entren	Test	Entren	Test	Entren	Test	Entren	Test
1	0,6329	0,5587	0,5784	0,5020	0,5615	0,4633	0,4680	0,4131	0,4546	0,3731
2	0,5032	1,7434	0,4617	1,5731	0,4475	1,5140	0,4513	1,5239	0,4513	1,5239
3	0,6643	0,2747	0,6071	0,2422	0,5912	0,1941	0,4982	0,1350	0,4818	0,1234
4	0,6140	0,7316	0,5664	0,6128	0,5496	0,5730	0,4562	0,5028	0,4565	0,4998
5	0,6764	0,1647	0,6206	0,1185	0,6021	0,0933	0,6123	0,1803	0,5948	0,1605
6	0,6731	0,1993	0,6119	0,2032	0,5935	0,1759	0,4944	0,1769	0,4944	0,1769
7	0,6764	0,1637	0,6136	0,1840	0,5943	0,1652	0,6041	0,2338	0,6041	0,2338
8	0,5000	1,7730	0,4537	1,6477	0,4486	3,3396	0,3183	15,6935	0,3183	15,6935
9	0,6752	0,1838	0,6118	0,2090	0,5953	0,1643	0,4988	0,1355	0,4815	0,1352
10	0,6316	0,5711	0,5709	0,5718	0,5547	3,8111	0,5671	0,5751	0,5671	0,5751
EVC	0,6247	0,6364	0,5696	0,5864	0,5538	1,0494	0,4969	1,9570	0,4904	1,9495
			E.PRED	0,5707	0,3574					

Nota: Todos los resultados están multiplicados por 10^2 . Probamos con distinto número de funciones base y no aportaba ninguna mejora en los resultados

REFERENCIAS

- Adedeji, A. y M McCosh, 1995. Determinants of Eurobonds Yield, *Journal of Business Finance and Accounting* 22, 1107-1124.
- Altman, E., Marco, G y F. Varetto, 1994. Corporate Distress Diagnosis: Comparisons Using Linear Discriminant Analysis and Neural Networks, *Journal of Banking and Finance* 18, 505-529
- Back, B., Laitinen, T., Sere, K. y M. Wezel, 1995. Choosing Bankruptcy Predictors Using Discriminant Analysis, Logit Analysis, and Genetic Algorithms, en Guillermo J. Sierra y Enrique Bosón: *Artificial Intelligence in Accounting, Finance and Tax*, 377-356.
- Barnhill, T.M., Joutz. F.L. y W.F. Maxwell, 2000. Factors Affecting the Yields on Noninvestment Grade Bond Indices: a Cointegration Analysis, *Journal of Empirical Finance* 7, 57-86.
- Bonilla, M., Olmeda, I. y R. Puertas, 2002. Modelos Parametricos y no Paramétricos en Problemas de Credit Scoring, *Revista Española de Financiación y Contabilidad*, aceptado y pendiente de publicación.
- Bose, S., 2003. Multilayer Statistical Classifiers *Computational Statistics & Data Analysis*, *Computational Statistics & Data Analysis* 42, 685-701.
- Bradley, F., 1991. Neglected Factors in the Market Pricing of Eurodollar Bonds. *The Journal of Portfolio Management*, winter, 62-73.
- Carson, J. y R. Hoyt, 2000. Evaluating the Risk of Life Insurer Insolvency: Implications from the US for the European Union, *Journal of Multinational Financial Management* 10, 297-314.
- Clare, A.D., Currim, M., Priestley, R. y S.H. Thomas, 2000. Modelling the Risk Premium on Eurodollar Bond, *The Journal of Fixed Income*, march, 61-74.
- Clark, E., Levasseur, M. y P. Rousseau, 1993. *International Finance*, Chapman and Hall, 3^o edition. 421 -451.
- Craven, P. Y G. Wahba, 1979. Smoothing Noisy Data with Spline Functions. Estimating the Correct Degree of Smoothing by the Method of Generalized Cross-Validation, *Numerische Mathematik* 31, 317-403.
- Datta, S., Iskandar-Datta, M. y A. Patel, 1999. Bank Monitoring and the Pricing of Corporate Public Debt, *Journal of Financial Economics* 51, 435-449.
- Duffee, G., 1998. The Relation Between Treasury Yields and Corporate Bond Yield *Spreads*, *Journal of Finance* 53, 2225-2241.
- Finnerty, J.E. y K.P. Nunn, 1985. The Determinants of Yield *Spreads* on US and Eurobonds, *Management International Review* 25, 23-33.
- Friedman, J.H., 1977. A Recursive Partitioning Decision Rule for Nonparametric Classification, *IEEE Transactions on Computers*, 404-509.
- Friedman, J.H., 1991. Multivariate Adaptive Regression Splines (with discussion), *The Annals of Statistics* 19, 1-141.
- Frydman, H., Altman, E. y D. Kao, 1985. Introducing Recursive Partitioning for Financial Classification: The Case of Financial Distress, *The Journal of Finance*, 269-291.

- Kidwell, D., Marr, M.W. y G.R. Thompson, 1985. Eurodollar Bonds: Alternative Financing for U.S. Companies, *Financial Management* 14, 18-27.
- Kish, R., Hogan, K.M. y G. Olson, 1999. Does the Market Perceive a Difference in Rating Agencies?, *The Quarterly Review of Economics and Finance* 39, 363-377.
- Leibowitz, M., Krasker, W. y A. Nozari, 1990. Spread Duration: A New Tool for Bond Portfolio Management, *The Journal of Portfolio Management*, 46-53.
- Litterman, R. y T. Iben, 1991. Corporate Bond Valuation and the Term Structure of Credit Spread, *The Journal of Portfolio Management*, 52-64.
- Macaulay, F.R., 1938. *Some Theoretical Problems by the Movements of Interest Rates, Bonds, Yields and Stock Prices in the United States since 1856.* Columbia University Press, Nueva York.
- Marais, M.L., Patell, J. y M. Wolfson, 1984. The Experimental Design of Classification Models: An Application of Recursive Partitioning and Bootstrapping to Commercial Bank Loan Classifications, *Journal of Accounting Research*, 87-114.
- Martí, M.L., 2001. *El Spread en el Mercado de Eurobonos: la Eficiencia de los Emisores en el Mercado Primario*, Tesis Doctoral. Universidad de Valencia.
- Meneu, V., Navarro, E. y M^aT. Barreira, 1992. *Análisis y Gestión del Riesgo de Interés*, Ariel Economía.
- Moisen, G.G. y T.S. Frescino, 2002. Comparing Five Techniques for Predicting Forest Characteristics, *Ecological Modelling* 157, 209-225.
- Morgan, J.N. y J.A. Sonquist, 1963. Problems in the Analysis of Survey Data, and a Proposal, *Journal of the American Statistical Association* 58, 415-434.
- Novak, M.P. y E. LaDue, 1999. Application of Recursive Partitioning to Agricultural Credit Scoring, *Journal of Agricultural & Applied Economics* 31, 109-122.
- Okashima, K. y M. Fridson, 2000. Downgrade/Upgrade Ratio Leads Default Rate, *The Journal of Fixed Income*, September, 18-24.
- Olmeda, I. y S. Barbe-Romero, 1993. *Redes Neuronales Artificiales: Fundamentos y Aplicaciones*, Servicio de Publicaciones de la Universidad de Alcalá de Henares, Madrid.
- Puertas, R., 2000. *Modelos no Paramétricos en Problemas de Clasificación Financiera*, Tesis Doctoral. Universidad de Valencia.
- Scholtens, B., 1999. On the Comovement of Bond Yield *Spreads* and Country Risk Ratings, *The Journal of Fixed Income*, 99-103.
- Solnik, B., 1996. *International Investments*, Addison Wesley, 3th Edition.
- Stone, M., 1974. Cross-Validatory Choice and Assessment of Statistical Predictions, *Journal of the Royal Statistical Society* 36, 11-144.
- Tam, K. y M. Kiang, 1992. Managerial Applications of Neural Networks: The Case of Bank Failure Predictions, *Management Science* 38, 926-947.
- Theobald, D., 1997. *Valuing European Fixed Income Markets*, JP Morgan, October.
- Thomas, L.C., 2000. A Survey of Credit and Behavioural Scoring: Forecasting Financial Risk of Lending to Consumers, *International Journal of Forecasting* 16, 149-172.
- Van Horne, J.C., 2001. *Financial Market Rates and Flows*. Prentice Hall, New Jersey
- Varetto, F., 1998. *Genetic Algorithms Applications in the Analysis of Insolvency Risk*,