

Universidade de Vigo
Departamento de Economía Aplicada

Documento de Trabajo
0303

**Métodos no-lineales de predicción en el mercado
de valores tecnológicos en España.
Una verificación de la hipótesis débil de eficiencia**

Marcos Álvarez-Díaz
Lucy Amigo Dobaño

Documentos de Trabajo

Marzo 2003

Departamento de Economía Aplicada
Universidade de Vigo
As Lagoas Marcosende S/N, 36310 –Vigo
Tfno: +34 986 812500 - Fax: +34 986 812401
<http://www.economiaaplicadavigo.org/>
E-mail: depx06@uvigo.es

**MÉTODOS NO-LINEALES DE PREDICCIÓN EN EL MERCADO DE
VALORES TECNOLÓGICOS EN ESPAÑA. UNA VERIFICACIÓN DE LA
HIPÓTESIS DÉBIL DE EFICIENCIA.**

Marcos Álvarez Díaz

Department of Applied Economics
University of Vigo
Lagoas-Marcosende s/n
36200 VIGO (Spain)
Phone: +34 986 81 4072
Fax: +34 986 812401
e-mail mad@uvigo.es

Lucy Amigo Dobaño

Department of Applied Economics
University of Vigo
Lagoas-Marcosende s/n
36200 VIGO (Spain)
Phone: +34 986 81 2505
Fax: +34 986 812401
e-mail lamigo@uvigo.es

Resumen

En los últimos años, ante los hallazgos de estructuras deterministas no-lineales en series financieras, la econometría financiera aplicada ha adoptado toda una serie de sofisticadas y potentes técnicas no-lineales de predicción. En este trabajo empleamos el método de ocurrencias análogas, redes neuronales y algoritmos genéticos para predecir la evolución del índice representativo del mercado de valores tecnológicos español, el Ibex Nuevo Mercado. El objetivo perseguido se centra en verificar si existe una cierta capacidad predictiva en su dinámica y, de esta forma, refutar la hipótesis débil de eficiencia en el segmento de cotización caracterizado por su intenso crecimiento y volatilidad como es el tecnológico. Los resultados obtenidos sólo muestran ciertas posibilidades predictivas a 1 periodo empleando la red neuronal, y a 4 y 10 periodos utilizando el algoritmo genético.

Keywords: Stock Market efficiency, time series non linear forecasting

JEL: C14, C53, G14

MÉTODOS NO-LINEALES DE PREDICCIÓN EN EL MERCADO DE VALORES TECNOLÓGICOS EN ESPAÑA. UNA VERIFICACIÓN DE LA HIPÓTESIS DÉBIL DE EFICIENCIA.

1-. Introducción

La predicción de los mercados financieros ha sido un objetivo recurrente en la literatura financiera durante las últimas décadas. Sin embargo, a pesar del esfuerzo realizado y constatado en numerosos trabajos empíricos, no se han obtenido claras evidencias de predictibilidad corroborando, de esta manera, la *Hipótesis de Mercados Financieros Eficientes*. En su versión débil, la asunción de esta hipótesis implica la imposibilidad de predecir rentabilidades futuras en función de sus valores presentes y pasados (Fama, 1970). Su análisis se ha basado tradicionalmente en una perspectiva lineal. De esta forma, los modelos ARIMA han sido extensivamente empleados para la predicción de rentabilidades pero, la no significatividad estadística de los parámetros estimados así como su escasa capacidad predictiva, sólo han contribuido a evidenciar favorablemente el supuesto de eficiencia.

El descubrimiento de estructuras deterministas no-lineales en series temporales financieras ha originado que los investigadores reconozcan las limitaciones de las técnicas lineales tradicionales y la posibilidad de predecir rentabilidades empleando métodos capaces de explotar el determinismo existente.

Avances en el campo informático han permitido el desarrollo de potentes técnicas no-lineales de predicción. En los últimos años, la econometría aplicada ha adoptado toda una serie de herramientas predictivas ya utilizadas con asiduidad en otras disciplinas científicas. El *método de ocurrencias análogas* y las *redes neuronales* se constituyen como las principales técnicas empleadas en la predicción financiera. De forma más reciente se ha incorporado al análisis un novedoso procedimiento basado en las teorías darwinianas de selección natural y supervivencia. Estos procedimientos, denominados *algoritmos genéticos o evolutivos*, presentan toda una serie de ventajas frente a otras técnicas no-lineales de predicción. En primer lugar, a diferencia de las redes neuronales y de las técnicas basadas en ocurrencias análogas, los algoritmos genéticos obtienen explícitamente una ecuación matemática como aproximación a la verdadera y

desconocida dinámica de la serie analizada. Además, se presentan como un método más flexible que las redes neuronales ya que no requieren la costosa especificación de una arquitectura previa. Considerando estas ventajas y su potencial predictivo se puede pronosticar una mayor intensidad en su uso (Kaboudan, 2000).

Cobra especial importancia la posibilidad de emplear estas técnicas predictivas en los mercados de valores y, en concreto, en el sector de la *Nueva Economía*. Estos segmentos de cotización, integrados por las empresas del sector tecnológico, están caracterizados por un intenso crecimiento y, pesar de su elevada volatilidad, existe la creencia de que sus rentabilidades son, de alguna forma, más predecibles que otros sectores más maduros y estables (Peters, 1991).

En este trabajo realizamos un análisis comparativo de las principales técnicas no-lineales de predicción (método de ocurrencias análogas, redes neuronales y algoritmos genéticos). El objetivo perseguido se centra en comprobar si, empleando herramientas no-lineales, podemos conseguir cierta capacidad predictiva que permita rechazar la hipótesis débil de eficiencia en el mercado de valores tecnológicos español, representado por el índice bursátil Ibex Nuevo Mercado (Ibex NM). Consideramos que la aportación de nuestro trabajo a la literatura ya existente es doble. Por una parte se aborda el estudio de un mercado financiero reciente y poco estudiado en España como es el sector tecnológico. Por otro lado, aplicamos novedosas y potentes técnicas predictivas para anticipar la evolución del índice Ibex NM. Algunas de estas técnicas, como es el caso de los algoritmos genéticos, son muy recientes y están escasamente consideradas en la literatura financiera.

El trabajo se estructura en 5 secciones. Después de esta sección introductoria, se describen los datos empleados y se analizan las regularidades empíricas observadas. A continuación, en la sección 3, se explica la perspectiva metodológica empleada así como una descripción de los métodos predictivos propuestos para el análisis. En la sección 4 se presentan los resultados obtenidos y, por último, se finaliza con una sección dedicada a conclusiones.

2-. Nuevo Mercado: Comentarios y Regularidades Empíricas Observadas

En consonancia con la actuación de otros mercados financieros, se ha creado un mercado específico para la negociación de las acciones emitidas por empresas que desarrollan su actividad en sectores innovadores tecnológicamente y cuyo ámbito de negocio se podría incluir en lo que se denomina Nueva Economía. En España, su puesta en funcionamiento se produjo el 10 de abril de 2000 con diez empresas. Asimismo, el Comité Asesor Técnico del índice Ibex 35 decidió el lanzamiento de un nuevo índice sectorial denominado Ibex Nuevo Mercado compuesto por los valores negociados en el mismo con base 10.000 el día de su puesta en funcionamiento.

El comportamiento bursátil de las empresas relacionadas con las nuevas tecnologías ha sido muy irregular, caracterizándose por elevadas alzas en el año 1999 y un acusado declive a partir del 2000 debido al mal comportamiento de los mercados bursátiles, que es agravado en este caso por la sobrevaloración efectuada en la denominada burbuja especulativa tecnológica.

La base de datos empleada en el estudio está constituida por datos diarios del Nuevo Mercado de valores español. Concretamente disponemos de la serie diaria del Ibex NM en el período comprendido desde su puesta en funcionamiento el 10 de Abril de 2.000 hasta el 28 de Diciembre de 2.001 (431 observaciones diarias). Los datos han sido obtenidos de Sociedad de Bolsas, S.A.

El estudio que abordaremos seguidamente partirá de considerar -siguiendo una práctica habitual en los trabajos sobre modelización de series financieras-, que los datos que se representan son las tasas de rendimiento calculadas como primeras diferencias de la serie original:

$$Y_t = (1 - L) p_t \quad [1]$$

donde p_t es el valor del índice en el instante t (expresada en logaritmos) y la variable Y_t es el incremento correspondiente al día t ¹.

Con el objeto de abordar el análisis de la eficiencia en el Nuevo del Mercado español de valores de renta variable, previamente realizaremos un análisis descriptivo –Tabla 1 del Apéndice- de su índice representativo Ibox Nuevo Mercado, señalando algunos de sus rasgos básicos.

En primer lugar, cabe resaltar que, al igual que ocurre en la mayoría de las series financieras, se constata que la media es aproximadamente igual a cero, la función de distribución empírica no es normal (en particular, es leptocúrtica), al tiempo que se produce un reducido grado de autocorrelación en el nivel medio y existencia de estructura en varianza.

En concreto, se evidencian unas revalorizaciones medias máximas entorno al 8.4% frente a unas pérdidas muy significativas que alcanzaron hasta un 14.9% en el período analizado. Al mismo tiempo, cabe matizar también que, del análisis de la distribución de la serie se desprende la presencia de un sesgo hacia la izquierda, indicando la tendencia hacia rentabilidades negativas. Por otra parte, el estadístico de Jarque-Bera rechaza, para los niveles de significación convencionales, la hipótesis de normalidad de la distribución del índice, indicando leptocurtosis.

Analizando los valores del estadístico de Ljung-Box para las 10 y 20 primeras autocorrelaciones de las series comprobamos que, con los niveles de significación habitual, las series de rendimientos no reflejan estructura en el nivel medio². Al mismo tiempo, el análisis de la gráfica 2 verifica la existencia de una baja correlación lineal en la serie y, en consecuencia, la ausencia de una estructura lineal en el nivel medio. De esta forma, se corroboraría desde una perspectiva lineal la hipótesis de eficiencia en el segmento de valores tecnológicos español.

¹ Dicha serie ha sido definida en términos de logaritmos neperianos para estabilizar su varianza, teniendo en cuenta que la misma no es negativa y sí muy volátil. Véase a este respecto, Tauchen et al. (1996).

² Según se comprueba en el anexo, Tabla 1, el estadístico de Ljung-Box para las series de los cuadrados rechaza la hipótesis de incorrelación, lo cual pone de manifiesto la existencia de componentes autorregresivos en varianza. Sin embargo, la existencia de una estructura en varianza no implica capacidad predictiva en los rendimientos.

Por ello, como conclusión de este análisis preliminar, podríamos afirmar que el Nuevo Mercado en España, representado a través de su índice Ibex Nuevo Mercado, se ajustaría a la hipótesis débil de eficiencia y que ningún inversor, en función de los datos de rentabilidades anteriores, podría obtener información adicional sobre las expectativas del mercado.

3-. Métodos No-lineales de Predicción

Metodología

Recientes resultados empíricos y teóricos parecen soportar la idea de la existencia de estructuras deterministas no-lineales en series financieras. La presencia de estas estructuras implicaría la posibilidad de realizar predicciones más precisas que aquellas otras proporcionadas por un modelo estocástico lineal y, en concreto, por el modelo referente en la literatura: el paseo aleatorio. En este sentido, Hsieh (1989) descubrió que las oscilaciones observadas en series financieras pueden presentar dependencias no-lineales a pesar de ser linealmente incorreladas. En la literatura financiera existen numerosas aplicaciones empíricas que proveen evidencias en favor de la predicción no-lineal de series financieras (Fernández-Rodríguez y Sosvilla-Rivero, 1998).

Los trabajos de Takens (1981) y Casdagli (1989), entre otros, han establecido la metodología necesaria para la modelización no-lineal de series temporales. A partir de la serie original $\{r_t\}_{t=1}^T$ se construye una serie de M^i ($i=1, \dots, T-m+1$) vectores de la forma

$$M^i = (r_{t-\tau}, r_{t-2\tau}, \dots, r_{t-(m-1)\tau})$$

donde m se denomina dimensión de incrustación y τ el factor de retardo. Esta secuencia de vectores de dimensión m es conocida en la literatura como las “*m-historias*” de la serie temporal. Según el Teorema de Takens (1981), la trayectoria geométrica de esta secuencia de vectores conforma un objeto multi-dimensional en \mathfrak{R}^m que, para un m suficientemente elevado, mantiene inalteradas ciertas características del

verdadero pero desconocido proceso generador de los datos. Además, si la serie $\{r_t\}_{t=1}^T$ es determinista, el Teorema garantiza la existencia de una función $F : \mathfrak{R}^m \rightarrow \mathfrak{R}$ tal que $x_t = F(x_{t-\tau}, x_{t-2\tau}, \dots, x_{t-m\tau})$

Por tanto, el Teorema implica la posibilidad de anticipar la dinámica futura de la serie temporal considerando únicamente sus valores pasados. El problema consiste en encontrar una buena representación o aproximación funcional de $F(\cdot)$. Para el ámbito financiero, durante la última década se han aplicado diferentes métodos no-lineales que permiten reconstruir la regla determinista subyacente en los datos.

Las aproximaciones más empleadas fueron aquellas basadas en generalizaciones del método de ocurrencias análogas. Por ejemplo, Barkoulas y Travlos (1998) aplicaron el método de regresión localmente ponderada para anticipar la evolución del mercado bursátil griego, Fernández-Rodríguez, Sosvilla-Rivero y García-Artiles (1999) una regresión local para predecir el índice Nikkei y, por su parte, Satchell y Timmermann (1996) emplearon predictores locales baricéntricos ponderados exponencialmente para predecir las rentabilidades de los índices bursátiles de 12 países.

En los últimos años se puede observar una cierta predominancia del empleo de redes neuronales motivado, fundamentalmente, a su gran capacidad para aproximar cualquier forma funcional con un determinado grado de precisión. Por tanto, sería de esperar que, si existiese algún tipo de no-linealidades, las redes neuronales podrían explotarla para obtener predicciones mucho más precisas. Los trabajos de Gençay (1998) para el índice Dow-Jones y Qui (1999) para el índice S&P500, entre otros muchos, han proporcionado evidencias de predecibilidad no-lineal en el mercado financiero estadounidense utilizando redes neuronales. Fernández-Rodríguez, González-Martel y Sosvilla-Rivero (2000) aplican esta metodología para generar estrategias de inversión rentables sobre el Índice General de la Bolsa de Madrid mientras que Darrat y Zhong (2000) utilizan una red neuronal para anticipar la evolución del emergente mercado chino.

De forma muy reciente se puede destacar la utilización de los algoritmos genéticos. Estos procedimientos ya han demostrado su robustez para aproximar explícitamente la forma funcional $F(\cdot)$ en el análisis no-lineal de series temporales (Szpiro (1997),

Yadavalli et al. (1999), Álvarez et al. (2001)). Respecto a sus aplicaciones empíricas en el ámbito financiero podemos destacar los trabajos de Kaboudan (2000) donde se predicen rentabilidades de una serie de activos financieros estadounidenses y se generan estrategias de inversión rentables, Fernández-Rodríguez, González-Martel y Sosvilla-Rivero (2001) hacen lo propio para el Índice General de la Bolsa de Madrid, Allen y Karjalainen (1999) centran su análisis en el S&P500 y Fyfe et al. (1999) obtienen evidencias de ineficiencia en el mercado Británico.

Método de Ocurrencias Análogas

El método de los análogos se constituye como una de las principales y más concurridas técnicas de predicción no-lineal de series financieras. El método, inspirado en la predicción de sistemas dinámicos no-lineales (Farmer y Siderowich, 1987), pretende predecir la dinámica futura de una serie temporal analizando cómo ha evolucionado en el pasado ante situaciones similares. Por tanto, el método se basa en la detección de los vecinos más próximos al vector cuya evolución pretendemos predecir y en el análisis de sus evoluciones. En nuestra aplicación utilizamos una generalización del método de los análogos denominada regresión local. De forma breve, el procedimiento puede ser explicado por medio de una serie de pasos. En primer lugar, a partir de la serie temporal $\{r_t\}_{t=1}^T$ se construye la *matriz trayectoria*

$$M_{T-m+1, xm} = \begin{pmatrix} M^1 \\ M^2 \\ \vdots \\ \vdots \\ M^{T-m+1} \end{pmatrix} = \begin{pmatrix} r_1 & r_2 & \dots & r_m \\ r_2 & r_3 & \dots & r_{m+1} \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ r_{T-m+1} & r_{T-m+2} & \dots & r_T \end{pmatrix}$$

Una vez definida esta matriz, el siguiente paso consiste en seleccionar aquellas dinámicas pasadas similares al comportamiento reciente de la serie temporal. Para este propósito se buscan los K vectores M^i pertenecientes a \mathfrak{R}^m que minimicen la distancia Euclídea con respecto al vector que representa la dinámica presente (M^{T-m+1}). En notación formal, los K vecinos más próximos serán aquellos vectores tal que minimicen la función

$$dista(M^i, M^{T-m+1}) = \|M^i - M^{T-m+1}\| = \sum_{l=1}^m (r_{l,i} - r_{l,T-m+1})^2)^{\frac{1}{2}}$$

Por tanto, a partir del cálculo de las distancias se puede construir, por una parte, la *matriz N* con los K vectores más próximos a M^{T-m+1} y, por otra, la *matriz E* donde se recoge hacia qué valor ha evolucionado cada uno de los K vectores τ periodos en el futuro

$$N_{K \times (m+1)} = \begin{pmatrix} N^1 \\ N^2 \\ \vdots \\ N^K \end{pmatrix} = \begin{pmatrix} k_{11} & k_{12} & \dots & k_{1m} \\ k_{21} & k_{22} & \dots & k_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ k_{K1} & k_{K2} & \dots & k_{Km} \end{pmatrix}; \quad E_{K \times 1} = \begin{pmatrix} E^1 \\ E^2 \\ \vdots \\ E^K \end{pmatrix}$$

Por ejemplo, el vector N^l ha evolucionado hacia una rentabilidad E^l τ periodos en el futuro mientras que, por su parte, el vector N^K ha originado una rentabilidad E^K . El valor predicho de la rentabilidad futura ($\hat{r}_{T+\tau}$) a partir del vector M^{T-m+1} vendrá determinado por el modelo de regresión

$$\hat{r}_{T+\tau} = b_0 + b_1 \cdot r_{T-m+1} + b_2 \cdot r_{T-m+2} + \dots + b_m \cdot r_T$$

donde los coeficientes b_i han sido estimados por mínimos cuadrados ordinarios utilizando las matrices N y E ($b = (N'N)^{-1}N'E$)³.

Un aspecto fundamental en el ejercicio predictivo consiste en determinar adecuadamente la dimensión de incrustación (m) y el número de vecinos más próximos (K). De la selección óptima de estos parámetros depende en gran medida el éxito predictivo.

³ Se ha añadido a la matriz N una columna de unos para incorporar en la ecuación de regresión el regresor ficticio b_0 .

Para el caso de K , la consistencia de los estimadores NN requiere que el número de vecinos más próximos tienda al infinito a medida que se incrementa el tamaño muestral (T) pero a una menor tasa

$$\lim_{T \rightarrow \infty} K_T = \infty \qquad \lim_{T \rightarrow \infty} \left(\frac{K_T}{T} \right) = 0$$

En la literatura no existe una única regla para seleccionar K que sea asumida de forma generalizada. Por ejemplo, Diebold y Nason (1990) consideran adecuado $K = T^\alpha$ o $K = \alpha \cdot T$, donde $0 < \alpha \leq 1$. Por su parte, Casdagli (1989) recomienda determinar $K = 2 \cdot (m + 1)$ ya que, de esta forma, se obtienen buenos resultados en presencia de ruido.

Respecto a la determinación de la dimensión de incrustación (m) tampoco existe consenso. En nuestro trabajo, la determinación de ambos parámetros se llevará a cabo por medio de un procedimiento de prueba y error basado en la selección de aquella combinación de K y m que optimice un determinado criterio de ajuste para un subperiodo muestral destinado a este propósito (Casdagli, 1989). En concreto, en nuestro trabajo se emplearon valores comprendidos en un rango entre 2 y 10 para el caso de m y de 20 a 60 para el caso de K .

Algoritmos Genéticos

Los algoritmos genéticos permiten encontrar una solución óptima a partir de la evolución de una población inicial de soluciones alternativas. En particular, tiene por objetivo el buscar una expresión matemática que, dentro del espacio de posibles soluciones, mejor describa la dinámica presentada por una serie temporal.

DARWIN, el AG empleado en este trabajo, ya ha demostrado su capacidad predictiva tanto teórica (Alvarez et al. (2001)) como empíricamente (Álvarez-Díaz and Álvarez (2002)). Su funcionamiento se basa en la simulación en un ordenador del proceso evolutivo observado en la Naturaleza y puede ser explicado por medio de una serie de pasos iterativos.

Para empezar, en el primer paso se genera de forma aleatoria una población inicial de N ecuaciones matemáticas (cromosomas) por medio de una sencilla combinación aleatoria de operadores y operandos de la forma

$$S_j = ((A \otimes B) \otimes (C \otimes D)) \quad \forall 1 \leq j \leq N \quad (2)$$

en donde A, B, C y D son los argumentos (genes operandos) y el símbolo \otimes representa a los operadores matemáticos (genes operadores). Los argumentos considerados pueden ser números reales pertenecientes a un intervalo (coeficientes de las ecuaciones) o bien valores retardados de la variable $(x_{t-\tau}, x_{t-2\tau}, \dots, x_{t-m\tau})$. Por su parte, los operadores matemáticos (\otimes) empleados serán la suma (+), resta (-), multiplicación (\cdot) y división (\div), este último operador estará protegido para evitar cocientes entre 0 o números muy pequeños. También cabe la posibilidad de incluir otros operadores matemáticos (como el logaritmo o los trigonométricos, por ejemplo) pero a costa de incrementar la complejidad en el proceso de optimización funcional. Además, trabajos previos llevados a cabo con DARWIN así como con otros AG (Szpiro (1997), Yadavalli et al. (1999)) han demostrado la posibilidad de describir dinámicas complejas por medio de expresiones matemáticas construidas simplemente con los operadores aritméticos.

En el segundo paso, una vez determinada la población inicial, comienza el proceso evolutivo seleccionando aquellas ecuaciones que presentan una mayor fortaleza según algún criterio de ajuste. Para el caso de predicción puntual se ha determinado como criterio de fortaleza el *Error Cuadrático Medio Normalizado* definido como

$$ECMN_j = \frac{1}{Var(x_t)} \cdot \frac{\sum_{t=m+1}^M [x_t - \hat{x}_t]^2}{M} \quad (3)$$

donde $ECMN_j$ es el Error Cuadrático Medio Normalizado presentado por la ecuación j -ésima ($\forall 1 \leq j \leq N$), $Var(x_t)$ es la varianza de la serie temporal, \hat{x}_t el valor predicho y M el número total de observaciones destinadas a entrenar el AG. Una generalización de

esta expresión ha sido empleada como criterio de fortaleza en los AG de Szpiro (1997) y Yadavalli et al. (1999).

A continuación, todas las ecuaciones de la población inicial son clasificadas en orden decreciente según su $ECMN_j$. Las ecuaciones con valores muy elevados del ECMN son aniquiladas mientras que, por el contrario, las que poseen un valor más pequeño tienen una mayor probabilidad de supervivencia constituyendo la base de la siguiente generación.

Las ecuaciones supervivientes al proceso de selección son empleadas para generar a los individuos de una nueva generación (proceso de reproducción). Para ello se les aplican los denominados operadores genéticos: Clonación, Cruzamiento y Mutación. Con la clonación las mejores ecuaciones son copiadas exactamente a la siguiente generación. Por su parte, con el operador cruzamiento se seleccionan parejas de ecuaciones con pequeños valores de $ECMN_j$ para intercambiar partes de sus argumentos y operadores matemáticos. Por último, la mutación implica el reemplazamiento aleatorio de algún operador o argumento en un porcentaje reducido de ecuaciones.

En definitiva, la nueva población generada a partir de la población inicial estará constituida por individuos clonados, mutados y cruzados. A partir de este momento el proceso evolucionará repitiendo los pasos de selección y reproducción de forma iterativa en busca de aquella expresión matemática que menor $ECMN$ presente. Después de un número determinado de generaciones del proceso evolutivo, la iteración terminará y el AG ofrecerá explícitamente como resultado una ecuación matemática que considera óptima para representar la verdadera dinámica de la serie temporal.

Redes Neuronales

Este método no-lineal, inspirado en los estudios sobre el funcionamiento del cerebro y del sistema nervioso, ha sido empleado para resolver numerosos problemas económicos destacando, en gran medida, su aplicación en la predicción de series financieras. Una introducción básica al funcionamiento de las Redes Neuronales puede ser encontrada en Bishop (1995) y aplicaciones concretas al ámbito financiero en Gately (1996) y Deboeck (1994). En la literatura especializada se distinguen diferentes tipos de redes neuronales. Sin embargo, en la mayoría de las aplicaciones económicas y financieras se destaca el empleo generalizado de la red *feedforward backpropagation* (Wong, 1995). En su expresión estadística, esta red puede ser expresada como⁴

$$\hat{r}_t = \Phi \left(\beta_0 + \sum_{h=1}^H \beta_h \cdot \Psi_h \left(\alpha_0 + \sum_{j=1}^J \alpha_{hj} \cdot r_{t-j} \right) \right) \quad (1)$$

donde \hat{r}_t es el output del modelo. Las funciones $\Psi(\cdot)$ y $\Phi(\cdot)$ se denominan función de transferencia del *nivel oculto* y del *nivel output*, respectivamente. La red presenta J inputs (retardados de la variable r_t), H unidades de proceso (neuronas) en el nivel oculto y 1 output. Inicialmente, los pesos α_{hj} y β_h son determinados aleatoriamente adoptando valores dentro de un determinado rango. Por medio de un proceso iterativo de aprendizaje (backpropagation), los valores de estos pesos son modificados de forma que la diferencia entre el valor real y el valor estimado (output de la red neuronal) sea mínimo. Este proceso se lleva a cabo considerando una submuestra de observaciones denominada *conjunto de entrenamiento*. Una vez que el proceso de aprendizaje ha finalizado y se ha determinado un conjunto de pesos óptimos, es preciso validar los resultados en otro subconjunto de la muestra (*Conjunto de Validación*). Si el criterio de ajuste se comporta de manera similar en los conjuntos de entrenamiento y validación se podrá afirmar que nuestra red es consistente y permite *generalizar* adecuadamente la dinámica de la serie temporal. En caso contrario estaremos ante un problema de sobre-

⁴ El caso presentado se corresponde a una red neuronal con un único nivel oculto. Se ha demostrado que esta estructura con un número suficientemente elevado de neuronas puede modelizar cualquier función continua. Es posible trabajar con varios niveles ocultos e, incluso, con varios outputs en una misma red.

entrenamiento o sobre-parametrización exigiendo modificaciones en la arquitectura, en el tamaño del conjunto de entrenamiento o, en último caso, cambios en el tipo de red.

La principal ventaja de las redes neuronales consiste en su elevada capacidad para detectar y explotar la no-linealidad existente en los datos. En este sentido, se ha demostrado que son *aproximadores universales de funciones*. Por tanto, se ha constatado que una red neuronal feedforward backpropagation es capaz de aproximar cualquier función no-lineal con un determinado grado de precisión (Beale and Jackson, 1990). Sin embargo, para evitar una ausencia de generalización, es necesario especificar una arquitectura adecuada (número de inputs y de unidades de proceso, determinación de las funciones de transferencia...). La determinación de una arquitectura correcta exige un análisis extremadamente cuidadoso ya que incide en gran medida en el éxito de la red. En la literatura es posible encontrar reglas para definir estructuras pero ninguna es perfecta ni se ha asumido de forma generalizada (Yao, Lim and Poh, 1999). Una práctica muy común en la mayoría de las aplicaciones empíricas consiste en seleccionar una arquitectura por medio de un proceso de “*prueba y error*”. En nuestro trabajo seguimos esta perspectiva y, concretamente, consistió en seleccionar el número de inputs, el número de unidades de proceso y las funciones de transferencia que reportaban el mínimo error en un conjunto muestral destinado exclusivamente destinado a este propósito (*Conjunto destinado a la Selección de Parámetros*)⁵. Otro problema a resolver consistió en la excesiva variabilidad de los resultados ante diferentes pesos iniciales (Racine, 2001). La solución propuesta fue el de considerar óptima aquella arquitectura que optimizaba el criterio de ajuste después de operar la red con 30 modificaciones de los pesos iniciales.

⁵ La determinación de una arquitectura se suele considerar un arte pues requiere de la experiencia y habilidad del investigador. Las funciones de transferencia empleadas en nuestro estudio consistieron en la función tangente hiperbólica y lineal.

IV-. Resultados

La muestra objeto de nuestro análisis empírico contiene un total de 431 observaciones diarias del índice Ibex Nuevo Mercado. Siguiendo las recomendaciones existentes en la literatura (Yao and Tan, 2000), se ha dividido la muestra en un *Conjunto de Entrenamiento*, un *Conjunto de Selección de parámetros* y, finalmente, en un *Conjunto “Out-of-Sample”*. El *conjunto de entrenamiento*, compuesto por las 300 primeras observaciones, está reservado para la obtención de vecinos en el método de análogos, para el entrenamiento de la red neuronal y para la evolución del algoritmo genético. Es necesario que el tamaño de esta sub-muestra sea lo suficientemente grande para permitir un análisis representativo de la serie. El *Conjunto de Selección*, integrado por las 86 siguientes observaciones, permite seleccionar la dimensión de incrustación para cada uno de los métodos así como el número de vecinos más próximos (K) en el método de análogos y la arquitectura de la red neuronal⁶. Por su parte, para el *Conjunto Out-of-Sample* se reservan las 45 últimas observaciones. Esta última submuestra permitirá verificar la validez y consistencia predictiva de los métodos propuestos.

El criterio de ajuste adoptado será el Error Cuadrático Medio Normalizado (*ECMN*) definido en la ecuación (3). Este criterio, recomendado por Casdagli (1989), ha sido empleado en multitud de trabajos dedicados a la predicción de series financieras (Elms, 1994; Yao, Tan and Poh, 1999; Yao and Tan, 2000; Tenti, 1996). Se basa en la comparación de los errores del método no-lineal respecto a los errores que se obtendrían si se considerase la media de la serie como predictor. De esta forma, un valor del ECMN mayor que uno implicaría una capacidad predictiva peor que emplear la media como predictor. Por tanto, adoptando este criterio, consideraremos que un método es adecuado para la predicción a un determinado horizonte temporal si presenta un ECMN menor que uno en el conjunto “out-of-sample” y, además, este valor es consistente con los ECMN obtenidos en el conjunto de entrenamiento y selección.

⁶ En la tabla 2 se muestra el número de vecinos más próximos que optimizan el ECMN en el conjunto de selección. Por su parte, la red para todos los periodos de predicción mostró siempre la misma arquitectura optimizadora: una unidad de proceso con una función de transferencia tangente hiperbólica en el nivel oculto y una función de transferencia lineal en el output. La arquitectura obtenida mediante el proceso de “prueba y error” (función de transferencia no-lineal en el nivel oculto y lineal en el output) ha sido destacada en la literatura por su capacidad para aproximar cualquier función continua (Cybenko, 1989).

En las tablas 2, 3 y 4 se presentan los resultados de los métodos no-lineales para diferentes horizontes temporales. En el caso del *método de ocurrencias análogas*, se puede constatar la imposibilidad de predecir adecuadamente “out-of-sample” para todos los horizontes temporales analizados. Por su parte, considerando la red neuronal, a pesar de que el ECMN está próximo a uno, se verifica una cierta capacidad predictiva a un horizonte temporal. Analizando la consistencia del ECMN para los distintos conjuntos se podría afirmar que la red ha descubierto y explotado un cierto componente determinista en la dinámica de las rentabilidades del Índice Ibex Nuevo Mercado. También mencionar que, para predicciones a más de 1 periodo, la red neuronal no es capaz de generalizar mostrando en algunos casos ECMN bajos en los conjuntos de entrenamiento y selección y elevados en el conjunto out-of-sample. Este hecho pudiera estar indicando un problema de sobre-entrenamiento de la red antes que una ausencia de estructuras predecibles en los datos.

En la tabla 4 se muestran los resultados obtenidos y las ecuaciones finalmente supervivientes empleando el algoritmo genético DARWIN. Se debe destacar la consistencia de las predicciones a 4 y 10 periodos (valores del ECMN menores que uno y semejantes para todos los conjuntos). A 1, 3 y 6 periodos nos encontramos con cierta capacidad predictiva aunque se verifica un cierto empeoramiento en el conjunto “out-of-sample” mostrando una ausencia de generalización motivada, posiblemente, por un problema de sobre-parametrización. También resulta relevante mencionar que las aproximaciones matemáticas a la dinámica de las rentabilidades ofrecidas por el algoritmo presentan todas una estructura fuertemente no-lineal.

V-. Conclusión

En este trabajo realizamos un estudio comparativo de las principales técnicas no-lineales empleadas en la predicción financiera (método de ocurrencias análogas, redes neuronales y algoritmos genéticos). Nuestro análisis se centra en el recientemente creado mercado tecnológico español representado por el índice Ibex Nuevo Mercado. La elección de este segmento de cotización se justifica por su escaso estudio y, en segundo lugar, por la posible existencia de mayores oportunidades predictivas en comparación con otros segmentos más maduros y estables (Peters, 1991). El objetivo perseguido consiste en comprobar si, empleando una perspectiva no-lineal, podemos

lograr cierta capacidad predictiva que permita rechazar la hipótesis débil de eficiencia en el sector tecnológico del mercado bursátil español.

En general, los resultados obtenidos no muestran una gran capacidad predictiva por parte de los métodos no-lineales considerados en nuestra aplicación. Sólo la red neuronal permite confirmar la existencia de una leve estructura predecible a muy corto plazo (predicción a 1 día) y el algoritmo genético a 4 y 10 días. Nuestros resultados ponen de manifiesto que, a pesar de aplicar métodos predictivos sofisticados y potentes, no se pueden obtener buenas predicciones de las rentabilidades del Ibex Nuevo Mercado y, en consecuencia, poder refutar la hipótesis de eficiencia en el mercado tecnológico español. Basándonos en la literatura existente podemos ofrecer varias justificaciones a los resultados obtenidos. Una posibilidad consistiría en admitir la existencia de débiles estructuras no-lineales en la dinámica de las rentabilidades que no reportan importantes mejoras predictivas (Diebold y Nason, 1990). En este caso, aún existiendo dinámicas no-lineales, la imposibilidad de predecir implicaría una argumentación a favor de la eficiencia de los mercados. Otra posible explicación es admitir la existencia de un fuerte componente no-lineal potencialmente predecible pero todavía sería necesario emplear métodos más potentes que permitan una aproximación más precisa a la verdadera pero desconocida dinámica. En este sentido, futuras líneas de investigación podrían centrarse en los denominados métodos híbridos (combinación de diferentes técnicas predictivas como es el caso, por ejemplo, de las Redes Evolutivas) o bien en la explotación de los efectos sinérgicos que pudieran existir entre diferentes métodos predictivos (métodos basados en la fusión o, también denominado, composición de predicciones). Una última explicación, ofrecida por Stengos (1996) y quizás la más plausible en nuestra aplicación empírica, incidiría en la escasez de observaciones. En general, las series financieras se han caracterizado por mostrar complejas dinámicas, incluso caóticas. Un análisis preciso exigiría un número de observaciones extremadamente elevado. Ciertamente es muy probable que trabajar con una muestra tan corta no nos haya permitido llevar a cabo un análisis más preciso que explore adecuadamente las no-linealidades existentes en la evolución del Ibex Nuevo Mercado.

Referencias

Allen F. and Karjalainen R. (1999), "Using Genetic Algorithms to Find Technical Trading Rules", *Journal of Financial Economics*, 51, 245-271.

Álvarez A., Orfila A. and Tintoré J. (2001) "DARWIN- an Evolutionary Program for Nonlinear Modeling of Chaotic Time Series", *Computer Physics Communications*, forthcoming.

Álvarez-Díaz M. And Álvarez A. (2002) Forecasting Exchange Rates Using Genetic Algorithms, *Applied Economic Letters*, forthcoming.

Barkoulas J. y Travlos N. (1998) "Chaos in an Emerging Market? The Case of the Athens Stock Exchange. *Applied Financial Economics*, 1998, 8, 231-243.

Beale R. and Jackson T. (1990) *Neural Computing: An Introduction*, Adam Hilger, 1990.

Bishop C. M.(1995) *Neural Networks for pattern Recognition*, Oxford University Press, 1995.

Casdagli (1989) "Nonlinear prediction of chaotic time series", *Physica D*,35, pp. 335-356.

Cybenko G. (1989) "Approximation by Superposition of a Sigmoidal Function" *Mathematics of Control, Signals and Systems* 2, 303-314.

Darrat A. F. And Zhong M. (2000) "On Testing the Random-Walk Hypothesis: A Model-Comparison Approach" *The Financial Review*, 35, 105-124.

Deboeck G. J. (1994) *Trading on the Edge. Neural, Genetic, and Fuzzy Systems for Chaotic Financial Markets*, John Wiley & Sons, 1994.

Diebold F. X. y Nason J. A. (1990) Nonparametric Exchange Rate Prediction?, *Journal of International Economics*, 28, 315-332.

Elms D. (1994) Forecasting in Financial Markets, in *Chaos and Non-Linear Models in Economics. Theory and Applications*. Eds. J. Creedy y V. L. Martin, pp. 169-186.

Fama, E.F. (1970) "Efficient Capital Markets: a review of theory and empirical works". *Journal of Finance*. Vol.25. pp.383-417.

Farmer D. and Siderowich J. (1987) "Predicting Chaotic Time Series" *Physical Review Letters* 59, 845-848.

Fernández-Rodríguez F., González-Martel C. and Sosvilla-Rivero S. (2000) "On the Profitability of Technical Trading Rules based on Artificial Neural Networks: Evidence from the Madrid Stock Market" *Economics Letters*, 69, 89-94.

Fernández-Rodríguez F., González-Martel C. and Sosvilla-Rivero S. (2001) "Optimisation of Technical Rules by Genetic Algorithms: Evidence from Madrid Stock Market". *FEDEA Working Paper* No. 2001-14.

Fernández-Rodríguez F., Sosvilla-Rivero S. and García Artiles M. (1999) "Dancing with Bulls and Bears: Nearest Neighbour Forecast for the Nikkei Index" *Japan and the World Economy*, Vol. 11, 395-413.

Fernández-Rodríguez F. and Sosvilla-Rivero S. (1998) Testing Nonlinear Forecastability in Time Series: Theory and Evidence from EMS, *Economic Letters* 59, pp. 49-63.

Fyfe C., Marney J. P. and Tarbert H. F. E. (1999) "Technical Analysis versus Market Efficiency- a Genetic Programming Approach" *Applied Financial Economics*, 1999, 9, 183-191.

Gately E. (1996) *Neural Networks for Financial Forecasting*, Wiley Trader's Advantage, John Wiley & Sons, 1996.

Gençay R. (1998) "Optimization of Technical trading Strategies and the Profitability in

Security Markets”, *Economics Letters*, 59, 249-254.

Hsieh, D. A. (1989) “Testing for nonlinear dependence in daily foreign exchange rates”, *Journal of Business*, 62, 329-368.

Kaboudan M. A. (2000) “Genetic Programming Prediction of Stock Prices”, *Computational Economics*, 16, 207-236.

Peters E. E. (1991) *Chaos and Order in the Capital Markets*. New York, John Wiley & Sons, 1991.

Qui M. (1999) “Nonlinear Predictability of Stock Returns Using Financial and Economic Variables”, *Journal of Business & Economic Statistics*, 17, 4, 419-429.

Racine J. “On the Nonlinear Predictability of Stocks Returns Using Financial and Economic Variables”. American Statistical Association. *Journal of Business & Economic Statistics*. July 2001, 9, 3.

Satchell S. and Timmermann A. (1996) “Daily Returns in International Stock Markets: Predictability, Nonlinearity, and Transaction Costs” in *Nonlinear Dynamics and Economics*, eds. Barnett W., Kirman A. y Salmon M.

Stengos T. (1996) Nonparametric Forecasts of Gold rates of Return, in *Nonlinear Dynamics and Economics*, eds. Barnett W., Kirman A. y Salmon M.

Szpiro G. G. (1997) Forecasting chaotic time series with genetic algorithm, *Physical Review E*, 55, 3, 2557-2568.

Takens F. (1981) “Detecting Strange Attractors in Turbulence”, in D. A. Rand and L. S. Young (eds.): *Dynamical Systems and Turbulence*. Springer-Verlag, 366-381.

Tauchen, G., H. Zhang y H. Liu (1996). “Volumen, volatility and leverage: A dynamic analysis”, *Journal of Econometrics* 74, pp. 177-208.

Tenti P. (1996) "Forecasting Foreign Exchange Rates Using Recurrent Neural Networks", *Applied Artificial Intelligence*, 10, 567-581.

Wong B. K. (1995) A Bibliography of Neural Network Business Application research: 1988-September 1994, *Expert Systems* 12, 3.

Yadavalli V. K. Dahule R. K., Tambe S. S. And Kulkarni B. D. (1999) Obtaining Functional Form for Chaotic Time Series Evolution Using Genetic Algorithm, *American Institute of Physics*, 9, 3.

Yao J. and Tan C. L. (2000) "A Case Study on Using Neural Networks to Perform Technical Forecasting of Forex", *Neurocomputing* 34, 2000, 79-98.

Yao J., Tan C. L. and Poh H.L. (1999) "Neural Networks For Technical Analysis: A Study on KLCI", *International Journal of Theoretical and Applied Finance*, 2, 2, 221-241.

ANEXO

TABLA 1
REGULARIDADES EMPÍRICAS DE LAS RENTABILIDADES DIARIAS
EN EL NUEVO MERCADO
(08:04:2000-28:12:2001)

<i>Media</i>	-0.003
<i>Máximo</i>	0.084
<i>Mínimo</i>	-0.149
<i>Desv. típica</i>	0.030
<i>Asimetría</i>	-0.524
<i>Curtosis</i>	4.587
<i>J-B</i> <i>(p-valor)</i>	64.906 (0.000)
<i>Q(10)</i> <i>(p-valor)</i>	16.105 (0.097)
<i>Q(20)</i> <i>(p-valor)</i>	29.163 (0.085)
<i>Q₂(10)</i> <i>(p-valor)</i>	44.963 (0.000)
<i>Q₂(20)</i> <i>(p-valor)</i>	53.198 (0.000)

Notas:

- (i) J-B es el estadístico de Jarque-Bera que contrasta la hipótesis nula de normalidad. Entre paréntesis se presenta el p-valor.
- (ii) $Q(k)$ denota el estadístico de Box-Ljung para contrastar la hipótesis nula de incorrelación hasta de orden k en la serie y $Q_2(k)$ denota el mismo estadístico para la serie de los cuadrados. Entre paréntesis se representa el p-valor correspondiente, basado en la aproximación χ^2_k a la distribución del estadístico de Box-Ljung.

GRÁFICO 1
AUTOCORRELACIONES IBEX NUEVO MERCADO




TABLA 2
RESULTADOS DEL MÉTODO DE OCURRENCIAS ANÁLOGAS

MÉTODO DE OCURRENCIAS ANÁLOGAS				
Horizonte Predicción	Retardo	Nº Vecinos	ECMN Selección	ECMN “Out-of-Sample”
1	4	41	0.8980	1.0672
2	3	59	0.9244	1.1505
3	3	58	0.9030	1.1431
4	2	38	0.9930	1.2564
5	4	55	1.0113	1.0876
6	5	57	1.0004	1.0815
7	3	41	0.9492	1.0581
8	2	48	0.9117	1.1564
9	2	52	0.9886	1.0558
10	9	60	1.0442	1.0308

TABLA 3
RESULTADOS DEL MÉTODO REDES NEURONALES

RED NEURONAL				
Horizonte Predicción	Retardo	ECMN Entrenamiento	ECMN Selección	ECMN “Out-of-Sample”
1	4	0.9875	0.9488	0.9530
2	3	0.9879	0.9603	1.0395
3	2	0.9872	0.9600	1.0401
4	2	0.9908	0.9778	1.0288
5	5	0.9933	0.9812	1.0270
6	4	0.9902	0.9805	1.0447
7	2	0.9876	0.9805	1.0082
8	2	0.9889	0.9816	1.0162
9	2	0.9941	0.9824	1.0785
10	10	0.9962	0.9739	1.0774

Horizonte Predicción	TABLA 4. RESULTADOS DEL ALGORITMO GENÉTICO				Ecuación
	EMBEDDING	ECMN Entrenamiento	ECMN Test	ECMN Validación	
1	3	0.9639	0.9052	0.9973	$x_t = \left\{ x_{t-3} \cdot \left[\frac{(-6.44) \cdot x_{t-2}^2}{x_{t-3}} - 2.74 \right] \cdot (x_{t-3} + x_{t-2}) \right\}$
2	2	0.9610	0.9427	1.0212	$x_t = \left\{ x_{t-2} \cdot \left[6.57 - \frac{3.63 \cdot x_{t-3}}{x_{t-2}} - 5.66 \right] \cdot (x_{t-2} + x_{t-3}) \right\}$
3	9	0.9125	0.9798	0.9908	$x_t = \{ 3.36 \cdot x_{t-3} \cdot (x_{t-6} - x_{t-3}) \}$
4	4	0.9465	0.9399	0.9274	$x_t = \left\{ x_{t-7} \cdot x_{t-6} \cdot \left[(-2.83) + \left(7.45 \cdot x_{t-7} \cdot \left(x_{t-5} + \frac{x_{t-7}}{x_{t-5}} \right) \right) \right] \right\}$
5	3	0.9513	0.9478	1.4843	$x_t = \left\{ 1.36 \cdot \left[(5.37 \cdot x_{t-7}^2 \cdot x_{t-6}) \cdot \left(2.85 + \frac{x_{t-7}}{x_{t-5}} \right) \right] \right\}$
6	4	0.9665	0.9676	0.9992	$x_t = \left\{ x_{t-9} \cdot \left[\left(x_{t-9} - 0.64 \cdot \left(6.13 + \frac{x_{t-6}}{x_{t-9}} \right) \right) \cdot (x_{t-8} + x_{t-7}) \right] \right\}$
7	3	0.9321	0.9807	1.0772	$x_t = \left\{ x_{t-7} \cdot \left[\frac{x_{t-8} \cdot x_{t-9}}{x_{t-7} + x_{t-8}} - 5.72 \cdot x_{t-9} + x_{t-8} \right] \right\}$
8	5	0.9741	0.9533	1.0262	$x_t = \{ x_{t-12} \cdot [4 \cdot x_{t-9} + x_{t-10} - x_{t-12} - x_{t-11}] \}$
9	5	0.9582	0.9625	1.0893	$x_t = \{ (2 \cdot x_{t-10} - x_{t-11} + x_{t-13} + 2 \cdot x_{t-9}) \cdot (x_{t-11} + x_{t-12}) \}$
10	10	0.9554	0.9465	0.9444	$x_t = \left\{ x_{t-13} \cdot x_{t-18} \cdot \left[\frac{x_{t-10}}{x_{t-13}} - 2.59 + \frac{x_{t-18}}{x_{t-13}} \right] \cdot (-2.63) \right\}$

Relación de Documentos de Trabajo publicados

- 9901 Philippe Polomé: Experimental Evidence on Voting Manipulation in Referendum Contingent Valuation with Induced Value
- 9902 Xosé M. González y Daniel Miles: Análisis Envolvente de Datos: Un Estudio de Sensibilidad
- 9903 Philippe Polomé: Combining contingent valuation and revealed preferences by simulated maximum likelihood
- 9904 Eva Rodríguez: Social value of health programs: is the age a relevant factor?
- 9905 Carlos Gradín y M^a Soledad Giráldez: Incorporación laboral de la mujer en España: efecto sobre la desigualdad en la renta familiar
- 9906 Carlos Gradín: Polarization by sub-populations in Spain, 1973-91
- 9907 Carlos Gradín: Polarization and inequality in Spain: 1973-91
- 0001 Olga Alonso, José María Chamorro: How do producer services affect the location of manufacturing firms?. The role of information accessibility
- 0002 Coral del Río Otero: Desigualdad Intermedia Paretiana
- 0003 Miguel Rodríguez Méndez: Margins, Unions and the Business Cycle in High and Low Concentrated Industries
- 0004 Olga Alonso Villar: Large metropolies in the Third World: an explanation
- 0005 Xulia González y Daniel Miles: Wage Inequality in a Developing Country: Decrease of Minimum Wage or Increase of Education Returns
- 0006 Daniel Miles: Infrecuencia de las Compras y Errores de Medida
- 0007 Lucy Amigo: Integración de los Mercados de Cambio: Análisis rentabilidad-riesgo de la cotización Peseta/Dólar
- 0008 Eduardo L. Giménez y Manuel González-Gómez: Efficient Allocation of Land Between Productive Use and Recreational Use.
- 0009 Manuel González-Gómez, P. Polomé y A. Prada Blanco: Sesgo sobre la Información Obtenida y la Estimación de Beneficios en Entrevistas a Visitantes de un Espacio Natural
- 0010 M. Xosé Vázquez Rodríguez y Carmelo León: Preferencias Imprecisas y Contexto en la Valoración de Cambios en la Salud.
- 0011 Begoña Alvarez: Can we Identify Fraudulent Behaviour?. An Application to Sickness Absence in Spain
- 0012 Xulia González, Xosé M. González y Daniel Miles: La Transición de la Universidad al Trabajo: una Aproximación Empírica.
- 0013 Olga Cantó: Climbing out of poverty, Falling back in: Low Incomes' Stability in Spain
- 0101 Arancha Murillas: Investment and Development of Fishing Resources: A Real Options Approach
- 0102 Arancha Murillas: Sole Ownership and Common Property Under Management Flexibility: Valuation, Optimal Exploitation and Regulation
- 0103 Olga Alonso Villar; José-María Chamorro Rivas y Xulia González Cerdeira: An análisis of the Geographic Concentration of Industry in Spain
- 0104 Antonio Molina Abardes y Juan Pinto-Clapés: A Complete Characterization of Pareto Optimality for General OLG Economies
- 0105 José María Chamorro Rivas: Communications technology and the incentives of firms to suburbanize
- 0106 Luci Amigo Dobaño y Francisco Rodríguez de Prado: Incidencia del efecto día en los valores tecnológicos en España

- 0107 Eva Rodríguez-Míguez; C. Herrero y J. L. Pinto-Prades: Using a point system in the management of waiting lists: the case of cataracts
- 0108 Xosé M. González y D. Miles: Análisis de los incentivos en el empleo público
- 0109 Begoña Álvarez y D. Miles: Gender effect on housework allocation: evidence from spanish two-earned couples
- 0110 Pilar Abad: Transmisión de volatilidad a lo largo de la estructura temporal de swaps: evidencia internacional
- 0111 Pilar Abad: Inestabilidad en la relación entre los tipos forward y los tipos de contado futuros en la estructura temporal del mercado de swaps de tipos de interés
- 0112 Xulia González, Consuelo Pazó y Jordi Jaumandreu: Barriers to innovation and subsidies effectiveness
- 0201 Olga Cantó, Coral del Río y Carlos Gradín: What helps households with children in leaving poverty?: Evidence from Spain in contrast with other EU countries
- 0202 Olga Alonso-Villar, José María Chamorro-Rivas, Xulia González: Agglomeration economies in manufacturing industries: the case of Spain
- 0203 Lucy Amigo Dobaño, Marcos Álvarez Díaz y Francisco Rodríguez de Prado: Efficiency in the spanish stock market. A test of the weak hypothesis based on cluster prediction technique
- 0204 Jaime Alonso-Carrera y María Jesús Freire-Serén: Multiple equilibria, fiscal policy, and human capital accumulation
- 0205 Marcos Álvarez Díaz y Alberto Álvarez: Predicción no-lineal de tipos de cambio. Aplicación de un algoritmo genético
- 0206 María J. Moral: Optimal multiproduct prices in differentiated product market
- 0207 Jaime Alonso-Carrera y Baltasar Manzano: Análisis dinámico del coste de bienestar del sistema impositivo español. Una explotación cuantitativa
- 0208 Xulia González y Consuelo Pazó: Firms' R&D dilemma: to undertake or not to undertake R&D
- 0209 Begoña Álvarez: The use of medicines in a comparative study across European interview-based surveys
- 0210 Begoña Álvarez: Family illness, work absence and gender
- 0301 Marcos Álvarez-Díaz e Alberto Álvarez: Predicción no-lineal de tipos de cambio: algoritmos genéticos, redes neuronales y fusión de datos
- 0302 Marcos Álvarez-Díaz, Manuel González Gómez e Alberto Álvarez: Using data-driven prediction methods in a hedonic regression problem
- 0303 Marcos Álvarez-Díaz e Lucy Amigo Dobaño: Métodos no lineales de predicción en el mercado de valores tecnológicos en España. Una verificación de la hipótesis débil de eficiencia