

## I. INTRODUCCIÓN

La literatura académica viene documentando la existencia de rendimientos anormales vinculados a las salidas a bolsa. Es habitual que haya diferencias apreciables entre el precio de oferta y el cierre del primer día de cotización que no es fácilmente justificable. Generalmente, el cambio en el nivel de precios se concreta en forma de importantes ganancias. Dada la magnitud de estos movimientos, se ha dedicado un gran esfuerzo a la búsqueda de explicaciones. Son muchas las teorías que se han propuesto al respecto. Unas relacionan este rendimiento con el miedo a la maldición del ganador (Rock, 1986), prácticas de asignación de acciones (Hanley, 1993) o su uso como mecanismo de defensa ante demandas (Tinic, 1988) entre muchas otras. Recientemente Ritter y Welch (2002) han hecho un exhaustivo trabajo de revisión sobre el particular.

Este estudio pretende contribuir al estudio de la posibilidad de existencia de inercia como factor condicionante del rendimiento inicial. La noción de inercia, que es como se calificará a la dependencia temporal en este trabajo, no es nueva. La literatura ha registrado la existencia de autocorrelación en series de rendimientos de salidas a bolsa hace mucho tiempo. Ibbotson y Jaffe (1975) descartaron que la distribución de rendimientos iniciales en las salidas a bolsa fuese aleatoria al encontrar dependencia entre el rendimiento promedio durante el primer mes de cotización de las acciones admitidas durante un mes determinado y el promedio correspondiente al siguiente. Ritter (1984) repitió el experimento empleando una serie que incluía los datos anteriores complementados, a partir de un momento, con otra serie de medias mensuales de rendimientos asociados al primer día de cotización. Por otro lado, introdujo la novedad de segmentar la muestra de compañías en función de la pertenencia o no al sector de los recursos naturales para llegar a la conclusión de que esto influía de forma notable en los resultados. Posteriormente, Ibbotson et al (1988) complementaron el estudio de Ritter sobre una serie ampliada sin segmentar. Los mismos autores volvieron a poner al día su trabajo en 1994. Sobre una serie ampliada que abarcaba un periodo de 33 años encontraron autocorrelación de primer orden en las series mensuales de 0,66. Un artículo más reciente de Lowry y Schwert (2002) realizó aportaciones relevantes. Además de contrastar que el fenómeno de la dependencia temporal en series mensuales se seguía manteniendo, ampliaron el estudio hasta contrastar la existencia de autocorrelación de orden doce. Hasta la fecha, los estudios se habían limitado a analizar el primer orden. Por otro lado, estudiaron la relación entre el rendimiento mensual medio y la cantidad de empresas admitidas a cotización mediante modelos de vectores autoregresivos. Según los autores, el elemento que relacionaría los elementos anteriores sería el ciclo de aprendizaje de los bancos de inversiones.

La primera aportación que se pretende realizar con este trabajo es trasladar el estudio desde las series mensuales hasta las series diarias. Consideramos que agrupar los datos de la forma que se ha realizado hasta el momento podría enmascarar la existencia de inercia en el corto plazo. La segunda sería el uso de modelos de series temporales para la predicción del movimiento del mercado de salidas a bolsa.

Frente a estudios anteriores, el análisis no se limitará a contrastar la existencia de autocorrelación. Se ajustarán diferentes modelos de series temporales que serán evaluados de acuerdo a su capacidad predictiva con el objeto de determinar si existe inercia explotable. Para ésto, se recurrirá a dos tipos de instrumento, los modelos ARIMA y las redes neuronales artificiales. El ajuste y evaluación de los modelos no sólo facilitarán un contraste para la existencia de inercia, una serie parcialmente predecible tiene como poco una estructura parcialmente determinista, sino que ayudará a evaluar hasta qué punto estas herramientas podrían ser incorporadas al abanico de posibilidades disponible para explicar la infravaloración de acciones concretas. La tercera contribución sería abordar el estudio explorando la posibilidad de existencia de mercados segmentados.

En su artículo de 1984, Ritter explica como a principios de la década de los 80, específicamente entre enero de 1980 y marzo de 1981, hubo un mercado de emisión de acciones extraordinariamente activo en el que las diferencias entre los precios de emisión y los de cierre del primer día de cotización fueron muy notables. En este entorno, el comportamiento del sector de los recursos naturales fue notable. Docenas de compañías de reciente creación dedicadas a la búsqueda de campos petrolíferos y de gas, actividades de refinó o extracción de carbón fueron sacadas a bolsa a precios de 10 centavos por acción y mostraron rendimientos iniciales espectaculares. Las perspectivas sobre su futuro hizo que sus rendimientos iniciales promedio se encontrasen en el orden del 110.9%, habitualmente seguidos de incrementos posteriores en el mercado secundario, frente al resto, que veían limitado su rendimiento inicial a una media del 21,0%. Tras el periodo en que el segmento mostró un comportamiento exuberante, la burbuja se deshinchó dejando tras si grandes pérdidas y una buena cantidad de demandas por parte de la Securities and Exchange Comisión por manipulación de precios. Ritter apreció que, en este contexto, tenía sentido estudiar de forma separada el comportamiento del rendimiento inicial de este segmento y el resto de las compañías. Las series mensuales de rendimientos iniciales promedio evidenciaban una estructura muy distinta, lo que podía desvirtuar el análisis. Es fácil ver el paralelismo ente la situación expuesta y lo que ocurrió a finales de la década de los noventa en el segmento de las Telecomunicaciones, Medios de Comunicación y Tecnología (TMT). De lo anterior se deduce que podría resultar interesante explorar la posibilidad de existencia de un mercado segmentado como el revelado por Ritter como vía para facilitar a una mejor comprensión de las razones que explican el comportamiento de las salidas a bolsa durante los años de la burbuja tecnológica. Por esta razón, se tendrá en cuenta la pertenencia o no al sector de moda durante los años del estudio a la hora de evaluar la dependencia temporal. La hipótesis subyacente es que diferencias en la estructura de los modelos y en la predecibilidad de los movimientos del mercado en función de la rama de actividad reforzarían la idea de existencia de segmentos.

El resto del trabajo tiene la estructura que sigue. En la segunda sección presentaremos la metodología y la muestra. La tercera desarrolla el análisis empírico y, finalmente, la cuarta se dedica a las principales conclusiones extraídas.

## II. METODOLOGÍA Y DATOS

## II.1. Índices de rendimiento inicial

La elaboración de los índices necesarios para estudiar la hipótesis de inercia debe partir de una definición concreta de rendimiento inicial. Siguiendo a la mayoría de los autores, definiremos el rendimiento inicial ajustado de una acción como la diferencia en porcentaje entre el precio de oferta y el precio de cierre del primer día ajustado por el rendimiento del índice general del mercado en que cotiza, es decir:

$$R_i = \left( \frac{Pc_i - Po_i}{Po_i} \right) - \left( \frac{Mc_i - Ma_i}{Ma_i} \right) \quad (1)$$

donde:

$R_i$ : Rendimiento inicial ajustado de la acción  $i$ .

$Po_i$ : Precio de oferta de la acción  $i$ .

$Pc_i$ : Precio de cierre de la acción  $i$ .

$Ma_i$ : Índice de mercado al cierre del día anterior en que la acción  $i$  fue admitida a cotización.

$Mc_i$ : Índice de mercado al cierre del día en que la acción  $i$  fue admitida a cotización<sup>4</sup>.

Dado que el estudio contempla la existencia de inercia sectorial, será necesario contar con un conjunto de series generado a partir de segmentos de la muestra global en función de sector de la actividad industrial. Para cada una de las muestras sectoriales se construirán series de medias ponderadas de rendimientos ajustados durante el primer día de cotización. El rendimiento medio de cada día se calculará dividiendo los rendimientos iniciales de las compañías admitidas a cotización entre el capital total emitido medido en dólares<sup>5</sup>.

$$RM_t = \frac{\sum_{i=1}^{n_t} (R_{it} * C_{it})}{\sum_{i=1}^{n_t} C_{it}} \quad (2)$$

donde:

$RM_t$ : Rendimiento medio para el día  $t$ .

$R_{it}$ : Rendimiento inicial ajustado de la acción  $i$  admitida a cotización el día  $t$ .

$C_{it}$ : Cantidad recaudada por la compañía  $i$  admitida a cotización el día  $t$ .

<sup>4</sup> Los índices empleados en el análisis fueron el S&P 500, el NASDAQ Composite y el AMEX Composite.

<sup>5</sup> Excluye las cantidades correspondientes a la opción de las entidades colocadoras para vender un número de títulos superior al ofrecido inicialmente conocida como green shoe.

El estudio sólo tendrá en cuenta los días en los que al menos una compañía empezó a cotizar. El resto no se incluirán en las series y, por tanto, no tendrán influencia en los resultados finales. Es razonable pensar que la distribución de días sin salidas a bolsa a lo largo del tiempo podría ser interpretado como un indicador de sentimiento del mercado que podría afectar al comportamiento de los inversores. Sin embargo, podría entenderse que la influencia de este hecho debe ser limitada en un mercado tan activo como el cubierto en este trabajo. En todo caso, es muy posible que el estudio de la influencia del patrón de los días sin salidas a bolsa fuese de interés.

Los índices empleados en el análisis fueron el S&P 500, el NASDAQ Composite y el AMEX Composite.

## II.2. Modelos de predicción

Cada una de las series de rendimientos medios será objeto de predicción empleando dos tipos de instrumentos: modelos ARIMA y redes neuronales artificiales<sup>6</sup>.

### II.2.1. Modelos ARIMA

Los modelos ARIMA(p,d,q), popularizados por Box y Jenkins (1970), son modelos lineales ampliamente empleados para el modelado de procesos estocásticos. Estos dependen de tres tipos de términos para el ajuste. El primero de ellos es una serie de parámetros de carácter autoregresivo. Según éstos, el valor  $w$  de una serie temporal en un instante  $t$  depende de como una combinación lineal de sus valores pasados hasta un desfase  $p$  más el error de predicción un periodo por delante correspondiente al periodo  $t$

$$w_t = \phi_1 \cdot w_{t-1} + \phi_2 \cdot w_{t-2} + \dots + \phi_p \cdot w_{t-p} + \alpha_t = \phi(L)w_t$$

El segundo, representado por  $d$ , recoge el orden de integración de la serie. Éste indica el número de diferencias que hay que tomar en el modelo original para lograr una transformación estacionaria. Por último,  $q$  se corresponde a la representación media móvil del proceso. En este caso, cada variable del proceso surge de la combinación lineal de los errores de predicción un periodo por delante cometidos en los  $q + 1$  periodos anteriores. Algebraicamente se representa de la forma:

$$w_t = \alpha_t + \theta_1 \cdot \alpha_{t-1} + \theta_2 \cdot \alpha_{t-2} + \dots + \theta_p \cdot \alpha_{t-q} = \phi(L)\alpha_t \quad (3)$$

Excluye las cantidades correspondientes a la opción de las entidades colocadoras para vender un número de títulos superior al ofrecido inicialmente conocida como green shoe.

---

<sup>6</sup> Todos los modelos ARIMA contenidos en este trabajo han sido estimados con Econometric Views 3.1. El trabajo con redes neuronales artificiales se realizó con Matlab 5.3 y la versión 2 de la toolbox de redes neuronales.

Todos los modelos ARIMA contenidos en este trabajo han sido estimados con Econometric Views 3.1. El trabajo con redes neuronales artificiales se realizó con Matlab 5.3 y la versión 2 de la toolbox de redes neuronales.

Si definimos  $L$  como un operador de retardos tal que  $Lw_t = w_t - 1$  podemos expresar el modelo completo como:

$$\phi(L).(1 - L)^d w_t = \phi(L).\varepsilon_t \quad (4)$$

donde  $\varepsilon_t$  es un proceso asimilable a un ruido blanco, es decir, una secuencia de variables independientes e idénticamente distribuidas (IID) de media cero y varianza constante.

En este trabajo modelos se ajustarán empleando información de los 100 días anteriores al que es objeto de predicción. Ésto es, se empleará una ventana deslizante de 100 días de rendimientos medios para ajustar los modelos y predecir el rendimiento medio del día 101, en el segundo paso se utilizarán los rendimientos del día 2 al 101 para predecir el 102 y así sucesivamente.

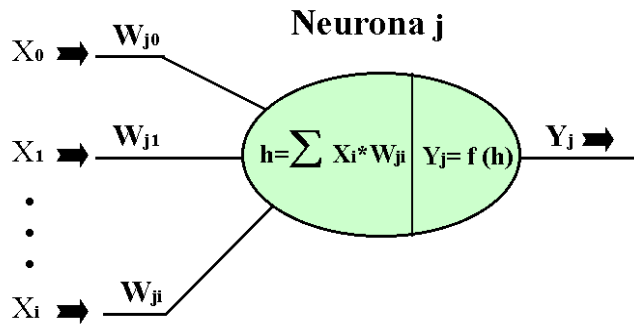
Con el objeto de escoger el modelo ARIMA adecuado, se contemplarán las posibilidades entre el ARIMA (0,0,0) y el ARIMA (5,3,5). El tamaño de ventana elegido no aconseja ajustar modelos más complejos. El término de integración se determinará usando el test Dickey-Fuller Aumentado (ADF) y los valores críticos propuestos por MacKinnon (1991) al 5%. La regresión incluirá constante, tendencia y cinco retardos. El análisis partirá de la segunda diferencia y, a medida que se vaya rechazando la hipótesis nula de la presencia de raíces unitarias se bajará sucesivamente a una diferencia y niveles.

Para cada ventana, se empezará determinando el grado de integración de la serie para, acto seguido, ajustar sucesivamente modelos para todas las combinaciones de términos AR y MA entre cero y cinco. Posteriormente, aquel que minimice el criterio información de Schwarz (1978) será seleccionado. Finalmente, el modelo elegido se empleará para predecir el siguiente elemento de la serie.

## II.2.2. Redes neuronales artificiales

Estos modelos de inspiración biológica se componen de una serie de unidades elementales, con capacidad de procesamiento simple, denominadas neuronas. Éstas se agrupan formando capas y se conectan entre sí a través de un tipo de enlace llamado peso. A través de estos pesos, la neurona puede tanto recibir como propagar la señal suministrada por otra neurona. Los pesos tienen la capacidad de atenuar o amplificar el resultado del procesamiento realizado en la unidad. El trabajo paralelo de procesamiento de estos elementos ponderados por la fuerza de estas conexiones permite aproximar funciones no lineales en función de unas variables explicativas.

GRAFICO N° 1



En el Gráfico N° 1 se muestra el diseño de una neurona artificial del tipo a utilizar en el trabajo. En este caso, la neurona  $j$ , recibe unos estímulos que se corresponden con salidas  $X_i$  de otras neuronas ponderadas por los pesos  $W_{ji}$ . La suma de estos estímulos entrantes es un valor  $h_j$ . Éste es procesado aplicándole una función de transferencia  $f$ . El resultado de esta transformación es un valor  $Y_j$  que se propagará a una o más neuronas. Otro elemento a destacar es el sesgo de la neurona  $\theta_j$ . Este valor corrige la función que, de otra manera, estaría centrada en el origen. En ocasiones, no es necesario explicitar el valor  $\theta_j$  y éste se representa como una entrada  $X_0$  de valor fijo e igual a uno ponderado por un  $w_{j0}$  que, de hecho, es  $-\theta_j$ .

$$Y_j = f(h_j, \theta_j) = f\left(\sum w_{ji} \cdot x_i - \theta_j\right) \quad (5)$$


La función de transferencia puede ser de muchos tipos. Normalmente se corresponde con la función logística, tangente hiperbólica, umbral o lineal. En este estudio se recurrirá a la tangente hiperbólica como función de transferencia en todas las neuronas a excepción de la de salida. La razón es que empíricamente se ha visto que la tangente hiperbólica suele estar asociada a entrenamientos más cortos<sup>7</sup>. La elección de una salida lineal se justifica para evitar limitar las posibles salidas al rango dinámico de la tangente hiperbólica. Matemáticamente, esta función tiene la forma

$$\tanh(\alpha) = \frac{e^\alpha - e^{-\alpha}}{e^\alpha + e^{-\alpha}} \quad (6)$$

<sup>7</sup> Bishop (1995), p. 127.

Las neuronas se agrupan en una estructura denominada red neuronal. De entre la gran cantidad de tipos de redes neuronales que existen, en este trabajo se emplearán las redes alimentadas hacia adelante (feedforward). Éstas se caracterizan por constar de una serie de capas de neuronas interconectadas entre sí de manera que cada capa se alimenta de la salida de las neuronas de una capa anterior, es decir, no existe ningún mecanismo de retroalimentación que haga que la salida de una neurona de una capa sirva de entrada a una neurona capa anterior. En el gráfico se puede apreciar la estructura de una red tipo de esta familia. En él queda de manifiesto la existencia de tres tipos de capas. La primera de ellas, conocida como capa de entrada, tiene por objeto introducir la información externa a la red. A continuación se encuentran las capas intermedias u ocultas, que pueden ser varias o ninguna y se caracterizan porque no tienen ningún tipo de contacto directo con el exterior. Finalmente se encuentra la capa de salida, que es la encargada de suministrar al exterior los resultados ofrecidos por el modelo.

GRÁFICO N° 2  
 MODELO DE RED NEURONAL ALIMENTADA HACIA DELANTE



Según esto, una vez determinado el tipo de neurona a utilizar, la estructura básica de estas redes neuronales quedaría determinada por el número de capas de la red; la cantidad de neuronas en cada capa y la estructura de conexión entre éstas. Una vez definidos estos parámetros, es necesario determinar el conjunto de valores en los pesos que facilite el valor que deseado ante un determinado patrón de entrada. Para ello se suele utilizar un algoritmo de ajuste, también llamado “de aprendizaje” o “de entrenamiento”. En este caso se recurrirá al algoritmo de retropropagación (Rumelhart et al, 1986) al que se añadirá una constante de momento con el objeto de acelerar la convergencia.

Para el análisis se usarán modelos de tres capas alimentados hacia adelante. La primera capa incluirá cinco neuronas y la tercera una. Esto es, la predicción de RMT se obtendrá a partir del rendimiento inicial promedio de los cinco días anteriores. En la

capa intermedia se emplearán entre tres y ocho neuronas. Cada serie se dividirá en un conjunto de patrones. Cada uno de ellos constará de los RMt correspondientes a seis días consecutivos. Cada patrón estará formado por dos partes. La primera, de cinco elementos, recogerá las variables explicativas. La segunda, el valor restante, será la variable dependiente. La generación de los patrones se hará desplazando una ventana deslizante de seis días por la serie. Una vez se cuente con la colección de patrones procederemos a ordenarlos de forma aleatoria. La predicción del sexto elemento de cada patrón se hará empleando los cinco primeros como entradas de una red neuronal que habrá sido ajustada previamente sobre el resto de muestra. El procedimiento detallado es el siguiente:

1. Extracción del primer patrón de la muestra.
2. División de la muestra restante en dos partes, un conjunto de entrenamiento y otro de validación.
3. Entrenamiento de redes neuronales probando distintas combinaciones de parámetros. Para una de ellas, las redes se ajustarán sobre el conjunto de entrenamiento hasta minimizar el error cuadrático medio sobre el conjunto de validación.
4. Selección de la red entre las entrenadas que minimice el error cuadrático medio sobre el conjunto de validación.
5. Predicción del sexto elemento del patrón previamente apartado empleando la red escogida en el punto anterior.
6. Devolución el patrón a la muestra.

Este proceso se repetirá para cada elemento muestral, con lo que se obtendrá un número de predicciones igual al tamaño de la serie menos cinco.

La capacidad de los dos tipos de modelos presentados será evaluada comparando su error cuadrático medio de predicción con el error cuadrático medio derivado del uso del periodo anterior como predicción para el segmento de la serie objeto de estudio<sup>8</sup>.

$$CP_m = \frac{\frac{\sum_{t=1}^n (RM_t - PRM_{m,t})^2}{n}}{\frac{\sum_{t=1}^n (RM_t - RM_{t-1})^2}{n}} \quad (7)$$

donde:

$CP_m$ : Capacidad predictiva del modelo  $m$ .

$RM_t$ : Rendimiento medio del día  $t$ .

$PRM_{m,t}$ : Predicción del rendimiento medio del día  $t$  empleando el modelo  $m$ .

Se podría entender que las ratios inferiores a uno indicarían que la serie es predecible, al menos parcialmente, empleando el modelo propuesto. Tal y como señalan

---

<sup>8</sup> El uso del valor observado en el periodo anterior, como predictor, en lugar del valor medio pretende controlar los problemas que podrían derivarse de ventanas en las que no se pudiera rechazar la presencia de raíces unitarias, caso en el que dicha medida no sería válida.



Diebold y Mariano (1995) la forma más sencilla de contrastar si estadísticamente se está logrando predecir es comparándolo con una F de Snedecor a niveles del 5 y 10%<sup>9</sup>.

### II.3. Tratamiento de elementos extremos

Cabe la posibilidad de que todas estas muestras contengan elementos extremos, por lo que será necesario contar con un procedimiento para tratar con ellos. Se considerarán dos posibilidades sobre la fuente de rendimientos diarios anormalmente altos o bajos.

1. Hay días excepcionales: durante éstos podría haber sucedido algún hecho relevante que hubiese alterado el mercado de salidas a bolsa en su conjunto y que deba tenerse en cuenta.

2. Hay compañías excepcionales: la causa del rendimiento promedio extremo observado en algunos días podrían ser operaciones específicas que, por alguna circunstancia, mostrasen un rendimiento ajustado muy elevado y distorsionasen el promedio diario.

En este trabajo se realizarán los ajustes necesarios para tener en cuenta ambas situaciones tal y como se explica a continuación.

Dado que, como se apreciará, se trata de series heterocedásticas, se ha recurrido a una definición de "elemento extremo" que parte del uso de ventanas deslizantes. Bajo la primera posibilidad, se considerará que un día presenta un valor extremo si RMt muestra un valor que está fuera de las bandas definidas por un número de desviaciones estándar calculadas a partir de una determinada cantidad de días. El número de desviaciones será escogido de forma que elimine la mayor parte de los elementos extremos. El número identificado como tal en los distintos casos se encuentra en el entorno del 2% de la serie. Una vez establecido el número de desviaciones inicial, se hará una segunda prueba empleando un criterio ligeramente más restrictivo, la cantidad de desviaciones anteriores menos una. El efecto que la consideración de extremo tendrá sobre un día será el siguiente:

1. Modelos ARIMA: uso de análisis de intervención (variable impulso).
2. Redes neuronales: exclusión de la fecha de la serie temporal.

El segundo criterio tiene por objeto identificar aquellos valores que muestran rendimientos ajustados extremos. De nuevo, se recurrirá al uso de ventanas deslizantes. El procedimiento es análogo al descrito con anterioridad. Una salida a bolsa será excluida de la muestra si el rendimiento ajustado de la acción en el primer día de cotización es inferior o superior a un número de desviaciones estándar calculadas a partir de una cantidad de compañías admitidas a cotización con anterioridad. Se considerará que todas las salidas a bolsa que tengan lugar el mismo días son simultáneas. Ésto

---

<sup>9</sup> Para utilizar este estadístico debemos asumir que se cumplen una serie de hipótesis, entre ellas que el error medio sea cero y que los errores estén incorrelacionados tanto temporalmente como entre modelos.

implica que todas las compañías admitidas a cotización el mismo día compartirán los mismos umbrales.

Dada la hipótesis de simultaneidad, cabe la posibilidad de que al sumar las operaciones diarias anteriores para el cálculo de la desviación estándar no se obtenga el número exacto definido a priori sino alguna más. En esta situación, se escogerá de forma aleatoria, de entre las compañías admitidas a cotización en la fecha más alejada entre las consideradas, el número necesario para alcanzar la cantidad apropiada para completar la ventana. A la vista de la muestra, se determinó que el número de desviaciones estándar empleada en la definición de las bandas que identificaba en cada caso la mayor parte de los elementos extremos filtraba, aproximadamente, el 3% de las operaciones. Tal y como se hizo anteriormente, el análisis se repetirá partiendo de un criterio más restrictivo que reduzca en una desviación el tamaño de cada una de las bandas. En este caso, aquellos valores identificados como extremos, serán extraídos de las muestras. Una vez hecho esto, se procederá a generar y predecir las series para analizar con posterioridad la capacidad predictiva de los distintos modelos.

1. Modelos ARIMA: uso de análisis de intervención (variable impulso).
2. Redes neuronales: exclusión de la fecha de la serie temporal.

Para utilizar este estadístico debemos asumir que se cumplen una serie de hipótesis, entre ellas que el error medio sea cero y que los errores estén incorrelacionados tanto temporalmente como entre modelos.

El segundo criterio tiene por objeto identificar aquellos valores que muestran rendimientos ajustados extremos. De nuevo, se recurrirá al uso de ventanas deslizantes. El procedimiento es análogo al descrito con anterioridad. Una salida a bolsa será excluida de la muestra si el rendimiento ajustado de la acción en el primer día de cotización es inferior o superior a un número de desviaciones estándar calculadas a partir de una cantidad de compañías admitidas a cotización con anterioridad. Se considerará que todas las salidas a bolsa que tengan lugar el mismo días son simultáneas. Esto implica que todas las compañías admitidas a cotización el mismo día compartirán los mismos umbrales.

Dada la hipótesis de simultaneidad, cabe la posibilidad de que al sumar las operaciones diarias anteriores para el cálculo de la desviación estándar no se obtenga el número exacto definido a priori sino alguna más. En esta situación, se escogerá de forma aleatoria, de entre las compañías admitidas a cotización en la fecha más alejada entre las consideradas, el número necesario para alcanzar la cantidad apropiada para completar la ventana. A la vista de la muestra, se determinó que el número de desviaciones estándar empleada en la definición de las bandas que identificaba en cada caso la mayor parte de los elementos extremos filtraba, aproximadamente, el 3% de las operaciones. Tal y como se hizo anteriormente, el análisis se repetirá partiendo de un criterio más restrictivo que reduzca en una desviación el tamaño de cada una de las bandas. En este caso, aquellos valores identificados como extremos, serán extraídos

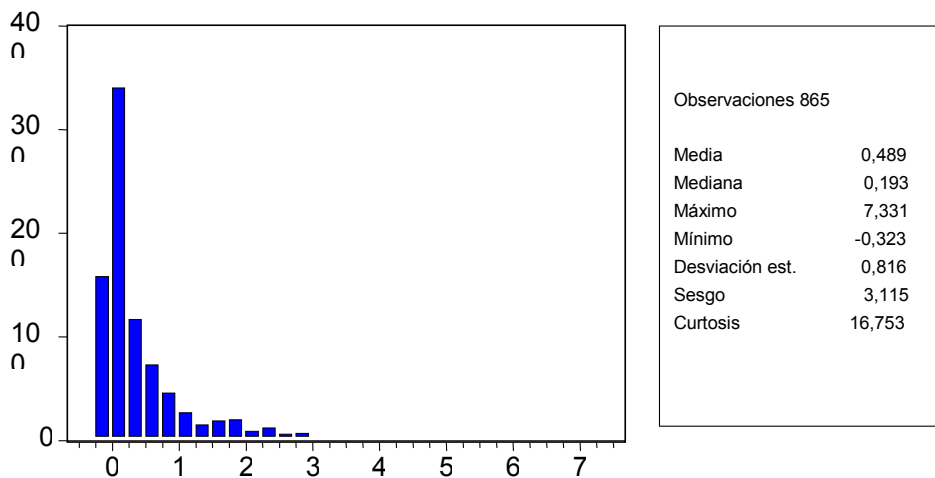
de las muestras. Una vez hecho ésto, se procederá a generar y predecir las series para analizar con posterioridad la capacidad predictiva de los distintos modelos.

#### II.4. Muestras

La muestra empleada consta de 865 salidas a bolsa que tuvieron lugar entre 5 enero de 1998 y el 17 de diciembre de 1999. Estos datos son relativos a todas las admisiones a cotización en el NASDAQ, AMEX y NYSE, excluyendo los ADRs y unit offerings<sup>10</sup>. La principal fuente de información ha sido Hoovers Online. En aquellos casos en los que el proveedor de información mencionado no disponía de precio de cierre para el primer día, se recurrió a IPO Data Systems como fuente secundaria. La información relativa a los índices fue obtenida de la NASD (los composites del NASDAQ y AMEX) y Bloomberg (S&P 500). El gráfico 1 muestra un histograma de los rendimientos iniciales considerados así como los principales estadísticos descriptivos asociados.

Venta conjunta de acciones y otro tipo de activos, normalmente warrants.

GRÁFICO N° 3  
HISTOGRAMA Y ESTADÍSTICOS DE RENDIMIENTO INICIAL



La existencia de cambios, tanto en la volatilidad, como en la estructura de los modelos lineales pueden estar provocando que las series de rendimientos iniciales presenten histogramas que se alejen de la normal. Al considerar ventanas pequeñas

<sup>10</sup> Venta conjunta de acciones y otro tipo de activos, normalmente warrants.

mencionadas con anterioridad, se reduce el riesgo de que, consideradas las series en su conjunto, puedan presentar problemas las estimaciones máximo verosímiles de los modelos con componentes medias móviles que requieren la hipótesis de normalidad de los residuos<sup>11</sup>.

#### II.4.1. TMT

La definición de TMT se apoya principalmente en el sector de actividad principal declarado por la compañía y especificado a través de un conjunto de cuatro cifras (código SIC) correspondientes al sistema de clasificación industrial desarrollado por el Departamento de Comercio de los Estados Unidos de América. Los códigos abarcados son: 2721, 3571, 3572, 3577, 3651, 3652, 3661, 3663, 3669, 3671, 3674, 3679, 4812, 4813, 4822, 4832, 4833, 4841, 4899, 7311, 7319, 7371, 7372, 7373, 7374 y 7375. En los apéndices se especifica la actividad específica que responde a cada uno de estos códigos.

Sin embargo, se considera que este primer criterio debe ser ampliado ya que podría dejar fuera de la primera muestra a compañías que hubiesen podido participar en la burbuja de las TMT. Para ilustrar este punto se recurrirá a los vendedores a consumidores de tipo doméstico que operan exclusivamente través de Internet. Si hubiese existido un comportamiento anómalo ligado a la burbuja de las TMT que hubiese podido manifestarse en forma de inercia, estas compañías deberían haber formado parte del fenómeno. Si embargo, al tener códigos SIC entre 52 y 59, serían excluidas bajo el primer propuesto. Por esta razón, también se incluirán las compañías cuya relación con la industria de las TMT en general, e Internet en particular, no es evidente a la vista del SIC primario.


Dado el ingente número de modelos considerados y la cantidad de ventanas utilizadas, no resulta sencilla la contrastación de la hipótesis de normalidad de los residuos de cada uno de ellos, pues dado el gran volumen de contrastes a realizar, la probabilidad de cometer errores, tanto de tipo I como de tipo II, es extremadamente elevada.

La versión extendida está fundamentada en las descripciones de negocio de los informes de IPO Data Systems. Las compañías que mencionan Internet como un pilar importante de su estrategia presente o futura serán incluidas en la muestra. Asimismo, las consultoras de tecnologías de la información también formarán parte de esta categoría. La muestra TMT incluye 531 elementos distribuidos en 227 días.

---

<sup>11</sup> Dado el ingente número de modelos considerados y la cantidad de ventanas utilizadas, no resulta sencilla la contrastación de la hipótesis de normalidad de los residuos de cada uno de ellos, pues dado el gran volumen de contrastes a realizar, la probabilidad de cometer errores, tanto de tipo I como de tipo II, es extremadamente elevada.

GRÁFICO N° 4  
SERIE TMT




Rendimiento promedio diario ajustado por el movimiento del mercado de las acciones clasificadas como TMT entre las admitidas a cotización (porcentaje). La muestra excluye unit offerings, ADRs y salidas a bolsa fuera del NYSE, NASDAQ o AMEX. Datos de Hoovers, IPO Data Systems, Bloomberg y NASD.

#### II.4.2. TMT1.

Esta muestra se define por diferencia, ya que incluye todas las compañías que no están incluidas en la categoría TMT y consta de 334 salidas a bolsa. Tras usar el procedimiento descrito con anterioridad, se obtiene una serie base de 206 elementos que aparece reflejada en el gráfico que sigue.

GRÁFICO N° 5  
SERIE TMT1



Rendimiento promedio diario ajustado por el movimiento del mercado de las acciones clasificadas como TMT1 entre las admitidas a cotización (porcentaje). La muestra excluye unit offerings, ADRs y salidas a bolsa fuera del NYSE, NASDAQ o AMEX. Datos de Hoovers, IPO Data Systems, Bloomberg y NASD.

### III. RESULTADOS Y DISCUSIÓN

Tal y como se avanzó, el análisis se divide en dos secciones, TMT y TMT1, en función de los sectores de actividad considerados y cada una de las en dos partes en función del sistema de predicción utilizado.

#### III.1. TMT

Como punto de arranque, se procederá a identificar elementos extremos usando los sistemas propuestos. Bajo la hipótesis de “días excepcionales” se emplearán ventanas de quince días y ocho y siete desviaciones estándar. Ésto conduce a marcar como extremos uno y seis días respectivamente. La detección de extremos bajo la hipótesis alternativa se apoya en ventanas deslizantes de cuarenta y cinco salidas a bolsa. Las bandas de ocho y siete desviaciones descartan dos y seis operaciones cada una.

Los principales estadísticos asociados a las series objeto de estudio se facilitan en la tabla que sigue:

TABLA N° 1  
ESTADÍSTICOS DEL CONJUNTO DE SERIES TMT

Serie	n	Prom.	Med.	Máx.	Mín.	Desv.	Sesgo
Completa	227	0,736	0,513	6,057	-0,323	0,799	2,450
Día 8	226	0,712	0,508	4,704	-0,323	0,718	1,682
Día 7	221	0,697	0,501	4,704	-0,323	0,714	1,755
Op. 8	226	0,708	0,507	4,704	-0,323	0,716	1,706
Op. 7	225	0,668	0,502	3,318	-0,323	0,633	1,146

Fuente: Elaboración propia en base a antecedentes de esta investigación.

Cada una de las filas representa uno de los filtrados propuestos. El primero de ellos, etiquetado como “Completa”, carece de intervención alguna. El segundo y tercero, “Día X”, muestra resultados para las series intervenidas bajo la hipótesis de días extraordinarios donde “X” representa el número de desviaciones empleadas como umbral para identificar elementos extremos. Los dos restantes “Op. X”, facilitan información relativa a la hipótesis de operaciones extraordinarias. Igual que antes, “X” indica el número de desviaciones estándar que se han utilizado para detectar elementos extremos. El contraste ADF al 5% lleva a descartar la existencia de raíces unitarias en las cinco series.

### III.1.1. ARIMA

El resultado de las predicciones mediante modelos ARIMA viene recogido en la tabla 2. En ella se facilitan resultados para las cinco series. Las ratios ponen de manifiesto que los modelos ARIMA aportan buenos resultados en todos los casos. Como se puede apreciar, se bate de forma significativa a valor de la serie en el período anterior como modelo de predicción para las cinco series.

TABLA N° 2  
EVALUACIÓN DE RENDIMIENTO: MODELOS ARIMA TMT

Serie	n	Prom.	Med.	Máx.	Mín.	Desv.	Sesgo
Completa	227	0,736	0,513	6,057	-0,323	0,799	2,450
Día 8	226	0,712	0,508	4,704	-0,323	0,718	1,682
Día 7	221	0,697	0,501	4,704	-0,323	0,714	1,755
Op. 8	226	0,708	0,507	4,704	-0,323	0,716	1,706
Op. 7	225	0,668	0,502	3,318	-0,323	0,633	1,146

Fuente: Elaboración propia en base a antecedentes de esta investigación.

\* Significativo al 5%

Frente a lo que cabría esperar, la proporción de ventanas que muestran una raíz unitaria es notable. El caso más extremo es el de la serie “Op. 7”, en la que un porcentaje muy alto de los modelos presentan esta característica. El uso de la ventana deslizante pone de manifiesto un rasgo que quedaba enmascarado al considerar la serie de forma conjunta. La inestabilidad de los modelos obtenidos es destacable. No es fácil encontrar más de tres períodos que tengan asociados modelos con la misma estructura. La mayor parte de las ventanas presenta una raíz unitaria y, es muy poco frecuente encontrar la segunda. Los modelos más comunes son (0,1,1), (1,1,0) pero el abanico de modelos que incluyen términos AR y MA de orden superior es amplio. R2 tiende a estar en torno a 0,6. En este caso, el filtrado de extremos propuesto no parece ser especialmente útil. Ambos criterios parecen mejorar los resultados pero, en ningún caso, de forma substancial.

### III.1.2. RNA

El segundo instrumento de predicción propuesto son las redes neuronales artificiales. Para cada serie se probarán estructuras de red que incluyen entre tres y ocho neuronas en la capa intermedia (NH). Cada una de ellas será entrenada durante 3000 ciclos empleando distintas combinaciones de tasas de aprendizaje (LR) y constantes momento (M). Las tasas de aprendizaje oscilan entre 0,001 y 0,003 con saltos de 0,001 (D) y las constantes de momento entre 0 y 0,001. El número de patrones incluidos en el conjunto de aprendizaje (TS) varía con el tamaño de la serie. Dada la naturaleza aleatoria de la inicialización de los pesos, las redes se entrenarán cuatro veces (R) para cada combinación de parámetros. El detalle de los parámetros de entrenamiento para todos los casos se encuentra recogido en el apéndice 2.



TABLA N° 3

Serie	ECM(RNA)	ECM(T-1)	Ratio
Completa	0,634	1,133	0,560*
Día 8	0,537	0,825	0,651*
Día 7	0,454	0,762	0,595*
Op. 8	0,486	0,809	0,600*
Op. 7	0,410	0,578	0,710*

Fuente: Elaboración propia en base a antecedentes de esta investigación.

\* Significativo al 5%

En términos de calidad las predicciones, las redes neuronales ofrecen unos resultados mejores que los modelos ARIMA en tres de los cinco casos. Entre las cinco posibilidades estudiadas sólo en las series en las que el criterio de identificación de elementos extremos está fundamentado en operaciones las redes muestran un comportamiento peor que los modelos lineales. Por lo demás, todas las series parecen mostrar fuertes indicios de ser parcialmente predecibles.

### III.2. TMT1

La serie TMT consta inicialmente de 206 elementos, incluyendo los elementos extremos. Aquel día que presente un R<sub>Mt</sub> superior a siete o seis desviaciones estándar calculadas sobre los quince días previos será etiquetado como extremo. El número de días identificados asciende a dos y cuatro respectivamente. El análisis compañía por compañía requiere seis y cinco desviaciones sobre una ventana deslizante de veinticinco operaciones. Dos y cuatro elementos son descartados en el proceso.

TABLA N° 4  
ESTADÍSTICOS DEL CONJUNTO DE SERIES TMT1

Serie	n	Prom.	Med.	Máx.	Mín.	Desv.	Sesgo	Curt.
Completa	206	0,119	0,061	1,603	-0,120	0,204	3,437	21,227
Día 8	204	0,106	0,058	0,725	-0,120	0,155	1,561	5,594
Día 7	202	0,102	0,055	0,683	-0,120	0,148	1,495	5,324
Op. 8	204	0,106	0,058	0,725	-0,120	0,155	1,548	5,594
Op. 7	203	0,102	0,057	0,683	-0,120	0,148	1,490	5,322

Fuente: Elaboración propia en base a antecedentes de esta investigación.

La comparación de estos estadísticos descriptivos con los que se obtuvieron con anterioridad pone de manifiesto notables diferencias. El rendimiento promedio en este segmento fue notablemente más bajo. Ésto no sólo se debió a algún caso aislado. La comparación de las medianas también revela valores notablemente más altos en las series del conjunto TMT. Por otro lado, el rango de valores en los que se mueven las medias diarias es mucho más estrecho, tanto por el lado de las pérdidas como el de las ganancias. Adicionalmente, frente al caso anterior, no se puede descartar la existencia al 5% de una raíz unitaria en ninguna de las cinco series del grupo.

### III.2.1. ARIMA

Los modelos ARIMA seleccionados parecen ser capaces de predecir hasta cierto punto tres de las cinco series de este conjunto. Sólo en estos casos la calidad de las predicciones de los modelos ARIMA es significativamente superior. Esto hace que las predicciones sean peores que las obtenidas para el conjunto de series complementario. En esta ocasión, la ratio sobre la serie completa es significativa al 10% en vez de al 5% y las intervenciones diarias no parecen mejorar los resultados.

TABLA N° 5  
EVALUACIÓN DE RENDIMIENTO: MODELOS ARIMA TMT1

Serie	ECM(ARIMA)	ECM(T-1)	Ratio
Completa	0,049	0,066	0,733**
Día 8	0,073	0,066	1,100
Día 7	0,054	0,066	0,811
Op. 8	0,022	0,035	0,615*
Op. 7	0,020	0,033	0,609*

Fuente: Elaboración propia en base a antecedentes de esta investigación.

\* Significativo al 5%

\*\* Significativo al 10%

La característica distintiva de los modelos ARIMA asociados a este grupo es la estabilidad. Aunque sigue sin ser alta, es significativamente superior a la anterior si excluimos los periodos dominados por modelos ARIMA(0,0,0). Aproximadamente la mitad de las ventanas presentan una raíz unitaria y, como en casos previos, los valores bajos para AR y MA predominan entre los modelos elegidos. Aún así, no son extraños los cuatros y los cincos en los componentes AR y MA.

### III.2.2. RNA

Las redes neuronales tienen más de éxito al predecir el conjunto de series. En los cinco casos parece que las redes son capaces de extraer una estructura que conduce a predicciones capaces de superar a la serie con un retardo.

TABLA N° 6  
EVALUACIÓN DE RENDIMIENTO: REDES NEURONALES

Serie	ECM(RNA)	ECM(T-1)	Ratio
Completa	0,040	0,054	0,739*
Día 8	0,027	0,038	0,705*
Día 7	0,024	0,033	0,748*
Op. 8	0,038	0,038	0,705*
Op. 7	0,023	0,033	0,692*

Fuente: Elaboración propia en base a antecedentes de esta investigación.

\* Significativo al 5%

Los resultados parecen indicar que las redes neuronales son algo superiores en este contexto. Sin embargo, una afirmación rotunda en el sentido de que una de las técnicas es mejor que otra no a vista de éstos no parece estar justificada. Cabe la posibilidad de que la comparación de la capacidad de los métodos empleados no se puede generalizar ya que los resultados podrían estar explicados por el criterio de selección de modelos. El criterio de información de Schwarz penaliza con dureza la sobreparametrización y, dada la reducida capacidad de ajuste de los modelos, podría estar afectando a los resultados de una forma notable. Por otro lado, el análisis realizado presenta la limitación de que las redes neuronales artificiales sólo consideran cinco retardos. Cabe la posibilidad que un número más elevado de neuronas en la capa de entrada hubiesen facilitado mejores resultados. Lamentablemente, restricciones tanto muestrales como de capacidad de cálculo afectan a este trabajo.

## CONCLUSIÓN

Este trabajo se ha estudiado la hipótesis de existencia de inercia sectorial en el rendimiento inicial de las compañías admitidas a cotización durante los años de la burbuja tecnológica. Para ésto, se ha dividido una muestra de compañías admitidas a cotización en los Estados Unidos en dos categorías en función de la pertenencia o no a los segmentos de Tecnología, Medios de Comunicación y Telecomunicaciones. A partir de estos datos, se han generado dos conjuntos de índices diarios que han sido objeto de predicción mediante modelos ARIMA y redes neuronales artificiales.

Los resultados sugieren que, durante el período cubierto, hubo cierto grado de inercia que afectó a los segmentos propuestos. Se ha llegado a esta conclusión a la vista del éxito de los modelos presentados para predecir, de forma parcial, la mayor parte de los índices elaborados. Dado que la series empleadas son diarias y que

los modelos no contemplaban muchos retardos, cabría pensar que podría existir una dependencia temporal a corto plazo a demás de la identificada en estudios anteriores sobre series mensuales.

La comparación de los dos grupos de índices propuestos pone de manifiesto claras diferencias tanto en los estadísticos descriptivos asociados a cada uno de ellos como en su predecibilidad. Por otro lado, la estructura de los modelos que mejor ajustan en cada caso parece ser distinta. Estos hechos sugieren que la forma en la que la inercia afecta al comportamiento del rendimiento inicial de las acciones está realmente relacionada con el sector de actividad. Estos indicios dotarían de consistencia a la hipótesis de existencia de un mercado segmentado tal y como el quedó de manifiesto en estudios previos.

Un factor a tener en cuenta a la hora de evaluar los resultados es que se está contrastando de forma simultánea la existencia de inercia y la validez de las especificaciones relativas a la selección y ajuste de los modelos. Ante resultados pobres no es fácil determinar la causa. En todo caso, parece que la calidad de las predicciones anima a seguir profundizando en el estudio de la hipótesis propuesta.

La detección de estructuras en los índices de rendimiento a corto plazo permitiría hacer predicciones diarias para el estado del mercado que facilitarían la posibilidad anticipar, al menos en parte, el precio de cierre de las acciones el día que son admitidas a cotización. Esto supone contar con una pieza más que contribuya a aclarar el origen del rendimiento inicial de las salidas a bolsa.

## REFERENCIAS

- BISHOP, C.M. 1995. *Neural Networks for Pattern Recognition*. Oxford University Press. Oxford.
- BOX, G.E.P. y JENKINS, G.M. 1970. *Time Series Analysis: Forecasting and Control*. Holden-Day. San Francisco.
- DIEBOLD, F.X. y MARIANO, R.S. 1995. Comparing Predictive Accuracy. *Journal of Business & Economic Statistics*, American Statistical Association, 13(3): 253-263.
- HANLEY, K.W. 1993. The Underpricing Of Initial Public Offerings and the Partial Adjustment Phenomenon. *Journal of Financial Economics (EE.UU.)* 34:231-250.
- IBBOTSON, R.G. y JAFFE, J.F. 1975. Hot Issue Markets. *Journal of Finance (EE.UU.)* 30:1027-1042.
- IBBOTSON, R.G.; SINDELAR J.L. y RITTER, J.R. 1988. Initial Public Offerings. *Journal of Applied Corporate Finance (EE.UU.)* 1:37-45.

- IBBOTSON, R.G.; SINDELAR, J.L. y RITTER, J.R. 1994. The Market's Problems With The Pricing of Initial Public Offerings. *Journal of Applied Corporate Finance* (EE.UU.) 7:66-74
- LOWRY, M. y SCHWERT, G.W. 2002. IPO Market Cycles: Bubbles or Sequential Learning?. *Journal of Finance* (EE.UU-) 57:1171-1200.
- MACKINNON, J.G. 1991. Critical Values for Cointegration Tests en Engle, R.F. y Granger, C.W.J. (Eds.) *Long-run Economic Relationships: Readings in Cointegration*. Oxford University Press. Oxford.
- TINIC, S.M. 1988. Anatomy of Initial Public Offerings of Common Stock. *Journal of Finance* (EE.UU.) 43:789-822.
- RITTER, J.R. 1984. The "Hot Issue" Market of 1980. *Journal of Business* (EE.UU.) 57:215-240.
- RITTER, J.R. y WELCH, E.I. 2002. A Review of IPO Activity, Pricing, and Allocations. *Journal of Finance* (EE.UU.) 57:1795-1828.
- ROCK, K. 1986. Why New Issues Are Underpriced. *Journal of Financial Economics* (EE.UU.) 15:187-212.
- RUMELHART, D.E., HINTON, G.E. y WILLIAMS R.J. 1986. Learning Representations by Back-propagating Errors. *Nature* (REINO UNIDO) 323:533-536.
- SCHWARZ, G. 1978. Estimating the Dimension of a Model. *Annals of Statistics* (EE.UU.) 6:461-464.

## APÉNDICE 1. DEFINICIÓN DEL SECTOR TMT

El sector de las TMT queda definido como aquel que cubre las actividades relacionadas con la tecnología, las telecomunicaciones y los medios de comunicación. Los códigos SIC asociados se detallan a continuación:

2721	Publicaciones periódicas: edición o edición e impresión
3571	Computadoras electrónicas
3572	Sistemas de almacenamiento para computadoras
3577	Periféricos para computadoras no clasificados en otra categoría
3651	Equipos domésticos de audio y vídeo
3652	Discos y cintas de audio grabadas
3661	Aparatos telefónicos y telegráficos
3663	Equipos de comunicaciones y emisión de radio y televisión
3669	Equipos de comunicaciones no clasificados en otra categoría
3671	Tubos electrónicos
3674	Semiconductores y elementos relacionados
3679	Componentes electrónicos no clasificados en otra categoría
4812	Comunicaciones de radiotelefonía
4813	Comunicaciones telefónicas salvo radiotelefonía
4822	Telegrafía y otros sistemas de comunicación fundamentados en mensajes
4832	Emisoras de radio
4833	Emisoras de televisión
4841	Cable y otros servicios de televisión de pago
4899	Servicios de comunicaciones no clasificados en otra categoría
7311	Agencias de publicidad
7319	Compañías del sector publicitario no clasificados en otra categoría
7371	Servicios de programación de computadoras
7372	Paquetes de Software
7373	Diseño de sistemas integrados por computadora
7374	Servicios de preparación y proceso de datos
7375	Proveedores de información

Fuente: Elaboración propia en base a antecedentes de esta investigación.

## APÉNDICE 2. PARÁMETROS DE ENTRENAMIENTO RNA

Parámetros empleados en búsqueda de estructuras adecuadas de red. Para cada definición de elemento extremo (Completa, Día y Op.), la tabla muestra los rangos de neuronas en la capa oculta (NH), tasas de aprendizaje (LR) y constantes de momento (M) proporcionando el tamaño de salto empleado (D). TS el tamaño del conjunto de entrenamiento. Para cada conjunto de parámetros las redes han sido entrenadas cuatro veces a partir de cuatro combinaciones aleatorias de pesos iniciales durante 3000 ciclos.

SERIE		NH			LR			M			TS
		MIN.	MAX.	$\Delta$	MIN.	MAX.	$\Delta$	MIN.	MAX.	$\Delta$	
TMT	Completa	3	8	1	0,001	0,003	0,001	0,0000	0,001	0,0005	178
	Día 8	3	8	1	0,001	0,003	0,001	0,0000	0,001	0,0005	178
	Día 7	3	8	1	0,001	0,003	0,001	0,0000	0,001	0,0005	174
	Op. 8	3	8	1	0,001	0,003	0,001	0,0000	0,001	0,0005	178
	Op. 7	3	8	1	0,001	0,003	0,001	0,0000	0,001	0,0005	177
TMT1	Completa	3	8	1	0,001	0,003	0,001	0,0000	0,001	0,0005	162
	Día 7	3	8	1	0,001	0,003	0,001	0,0000	0,001	0,0005	160
	Día 6	3	8	1	0,001	0,003	0,001	0,0000	0,001	0,0005	158
	Op. 6	3	8	1	0,001	0,003	0,001	0,0000	0,001	0,0005	160
	Op. 5	3	8	1	0,001	0,003	0,001	0,0000	0,001	0,0005	159

Fuente: Elaboración propia en base a antecedentes de esta investigación.