

Modelos de algoritmos genéticos y redes neuronales en la predicción del signo de variación del IPSA

Antonino Parisi F.

Universidad de Chile

Extracto

Este estudio analiza la capacidad de los modelos multivariados dinámicos recursivos construidos a través de algoritmos genéticos y de las redes neuronales recursivas para predecir el signo de las variaciones semanales del IPSA. Los datos corresponden al período comprendido entre el 14 de julio de 1997 y el 9 de diciembre de 2002. Los modelos analizados fueron evaluados en 60 series generadas por un proceso *block-bootstrap*. Los resultados señalan que la *red ward* tendría mayor capacidad que el modelo de algoritmos genéticos y el modelo naive para predecir el signo de las variaciones del IPSA, que ésta capacidad predictiva sería significativa, y que una estrategia de *trading* basada en las señales de compraventa dadas por este modelo permitirían obtener retornos relativamente más altos. Se destaca que la *red ward* y el modelo de algoritmos genéticos superaron, en promedio, a la estrategia *buy and hold*, aun cuando se consideró un costo por transacción equivalente al 0,1% del monto transado.

El autor desea agradecer a Franco Parisi, Jorge Gregoire y a un árbitro anónimo, por sus valiosos aportes y comentarios. También a Edinson Comejo y Katherine Schulz por su labor como asistentes de investigación.

CJEL: G10, G14 y G15

Palabras Clave: Algoritmos Genéticos, Redes Neuronales, *Red Ward*, *Directional Accuracy Test*, Porcentaje de Predicción de Signo, *Bootstrap*.

Abstract

This study analyzes the ability of the recursive dynamics multivaried models constructed through genetic algorithms and the recursive neuronal networks to predict the sign of the IPSA's weekly changes. The data correspond to the period between July 14, 1997 and December 9, 2002. The analyzed models were evaluated in 60 series generated by a block-bootstrap process. The results indicate that the network ward would have better forecast ability than the genetic algorithms model and the naive model to predict the sign of the IPSA's changes. The network ward and the genetic algorithms models surpassed, in average, the buy and hold strategy, even when a transaction cost of 0.1% is considered.

1. Introducción

Este estudio analiza la capacidad de los modelos multivariados dinámicos construidos a partir de algoritmos genéticos y de modelos de redes neuronales para predecir el signo de las variaciones semanales del índice de Precios Selectivo de Acciones (IPSA), perteneciente al mercado bursátil chileno. Predecir la dirección (alza o baja) del movimiento del índice bursátil podría ser relevante para desarrollar estrategias de transacción efectivas, las cuales pueden arrojar mejores resultados que aquellas basadas en la proyección del valor de la variable observada (Leung, Daouk & Chen, 2000). En este contexto, la contribución de este estudio radica en el análisis de la significancia estadística y económica de la capacidad predictiva de las técnicas ya señaladas, para finalmente determinar cuál de ellas es la más apropiada para el caso del IPSA chileno.

Nuestro análisis se centrará, por una parte, en el análisis de la capacidad predictiva de los modelos multivariados dinámicos construidos a partir de algoritmos genéticos. Por otra parte, se utilizarán las redes neuronales multicapas con aprendizaje supervisado, específicamente la *Red Ward*. Los resultados serán comparados con los de un modelo naive o ingenuo.

El documento se divide en cinco secciones: la sección dos presenta una revisión de la literatura relacionada a este estudio; la sección tres explica los aspectos metodológicos de la investigación; la sección cuatro aborda el análisis de los resultados y, finalmente, la sección cinco presenta las conclusiones.

2. Background

La hipótesis de mercados eficientes (Fama, 1970) plantea que el mercado refleja completa y correctamente toda la información relevante para la determinación de los precios de los activos. Dado que el surgimiento de nueva información es de carácter aleatorio, los cambios registrados por los precios accionarios también lo serían. Esto ha llevado a muchos analistas financieros y académicos a señalar que las fluctuaciones de las cotizaciones bursátiles siguen un camino aleatorio (*random walk*). Sin embargo, varios estudios han concluido que existe evidencia significativa de que los precios accionarios no siguen un camino aleatorio y muestran que los retornos accionarios son predecibles en algún grado. Por ejemplo, Lo & MacKinlay (1988), utilizando datos de mercados bursátiles desarrollados, tales como U.S.A., Europa Occidental y Japón registraron una correlación serial positiva entre los retornos semanales; Conrad & Kaul (1988, 1989) también encontraron evidencia de predictibilidad de los retornos en el corto plazo; DeBondt & Thaler (1985), Fama & French (1988), Poterba y Summers (1988) y Chopra, Lakonishok & Ritter (1992) hallaron una correlación serial negativa en los retornos de los activos individuales y varios portfolios sobre intervalos de tres a diez años. Por su parte, Jegadeesh (1990) examinó la predictibilidad de los retornos mensuales sobre activos individuales y encontró una correlación serial negativa de primer orden altamente significativa para rezagos de dos meses, y una correlación serial positiva para rezagos mayores. Blume, Easley & O' Hara (1994) presentaron un modelo que sugiere que existe una relación significativa entre los rezagos del volumen transado y los retornos actuales de los activos individuales.

Según Leung, Daouk & Chen (2000), la predicción de los retornos accionarios, dadas las variables agregadas en el set de información de los inversores, es un hecho que es aceptado en la reciente literatura de las finanzas empíricas, y las preguntas apuntan hacia cómo usar la información de una manera óptima para predecir y transar en los mercados. No obstante, el grado de

predictibilidad de los retornos es generalmente considerado económicamente no significativo, por lo que Hodgson & Nicholls (1991) sugieren evaluar la significancia económica de predecir la dirección de los cambios en los precios de los activos y no su nivel. En esta materia, Leung, Daouk & Chen (2000) compararon la capacidad predictiva de los modelos de clasificación ¹ con los de estimación de nivel ² y concluyeron que los primeros se desempeñan mejor que los segundos en términos de su tasa de acierto (medida por el número de veces en que la dirección pronosticada es correcta) y, además, son capaces de generar beneficios económicos más altos. Wu & Zhang (1997) investigaron la predictibilidad de la dirección del movimiento en el tipo de cambio spot futuro. Aggarwal & Demaskey (1997) encontraron que el desempeño de la cobertura cruzada mejora significativamente si se puede predecir la dirección de las variaciones en el tipo de cambio. Maberly (1986) analizó la relación entre la dirección de los cambios de precio interdía e intradía, y O'Connor, Remus & Griggs (1997) apoyan la utilidad de proyectar la dirección del cambio en el nivel de precios más que el nivel de precios en sí. Esto último resulta relevante para los analistas de mercado y para los traders, en el sentido de que apunta a que deben centrar sus esfuerzos en predecir con precisión la dirección de los movimientos del precio en vez de minimizar la desviación de las estimaciones de los valores observados.

A. *Algoritmos Genéticos*

Los algoritmos genéticos, introducidos por Holland (1975), consisten en una función matemática o una rutina que simula el proceso evolutivo de las especies, teniendo como objetivo encontrar soluciones a problemas específicos de maximización o minimización. Así, el algoritmo genético recibe como entrada una generación de posibles soluciones para el problema en cuestión, y arroja como salida los especímenes más aptos (es decir, las mejores soluciones), para que se apareen y generen descendientes, los que deberían tener mejores características que las generaciones anteriores. Los algoritmos genéticos trabajan con códigos que representan las posibles soluciones al problema. Por ello, es necesario establecer una codificación para todo el rango de posibles soluciones antes de comenzar a trabajar con el algoritmo. Al respecto, Davis (1994) señala

¹ Linear discriminant analysis, logit model, probit model y probabilistic neural network.

² Adaptive exponential smoothing, vector autoregression with Kalman filter, multivariate transfer function y multilayered feedforward neural network.

que la codificación más utilizada es la representación de las soluciones por medio de cadenas binarias (conjuntos de ceros y unos).

Según Bauer (1994), este método puede ser utilizado fácilmente en aplicaciones financieras. Davis (1994) muestra una aplicación de algoritmos genéticos en la calificación de créditos bancarios, resultando mejor que otros métodos como las redes neuronales, debido a la transparencia de los resultados obtenidos. Kingdom & Feldman (1995) señalaron haber usado algoritmos genéticos para hallar reglas que pronosticaran la bancarrota de las firmas, estableciendo relaciones entre los distintos ratios financieros. Bauer (1994) utilizó algoritmos genéticos para desarrollar técnicas de transacción que indicaran la asignación mensual de montos de inversión en dólares y marcos. Pereira (1996) los utilizó para encontrar los valores óptimos de los parámetros usados por tres reglas de transacción distintas para el tipo de cambio "dólar americano/dólar australiano": los parámetros obtenidos mostraron resultados intramuestrales positivos, los cuales disminuyeron al aplicar las reglas fuera de la muestra, aun cuando siguieron siendo rentables. Allen & Karjalainen (1999) usaron algoritmos genéticos para aprender reglas de transacción para el índice S&P 500 y emplearlas como un criterio de análisis técnico y, una vez cubiertos los costos de transacción, encontraron que el exceso de retorno calculado sobre una estrategia *buy and hold*, durante el período de prueba extramuestral, no era consistente. Kim & Han (2000) mostraron que los algoritmos genéticos pueden ser usados para reducir la complejidad y eliminar factores irrelevantes, lo que resultó mejor que los métodos convencionales para predecir un índice de precios. Por otra parte, Feldman & Treleaven (1994) señalaron que la mayor desventaja de los algoritmos genéticos es la dificultad que presentan para escoger una técnica de codificación manejable, y para determinar el tipo de selección y las probabilidades de los operadores genéticos, ya que no hay reglas fijas en esta materia.

B. Redes Neuronales

De acuerdo a Martín del Brío y Sanz (1997), las redes neuronales artificiales "son sistemas de procesamiento que copian esquemáticamente la estructura neuronal del cerebro para tratar de reproducir sus capacidades". En consecuencia, son una clase de modelos no lineales flexibles, que se caracterizan

por ser sistemas paralelos³, distribuidos⁴ y adaptativos⁵, todo lo cual se traduce en un mejor rendimiento y en una mayor velocidad de procesamiento. Las redes neuronales pueden entenderse como modelos multiecuacionales o multietapas, en que el output de unas constituye el input de otras. En el caso de las redes multicapas, existen etapas en las cuales las ecuaciones operan en forma paralela. Los modelos de redes neuronales, al igual que, por ejemplo, los modelos de suavizamiento exponencial y de análisis de regresión, utilizan inputs para generar un output en la forma de una proyección. La diferencia radica en que las redes neuronales incorporan inteligencia artificial en el proceso que conecta los inputs con los outputs (Kuo & Reitsch, winter 1995-1996).

Herbrich, Keilbach, Graepel, Bollmann-Sdorra & Obermayer (2000) señalan que la característica más importante de las redes neuronales es su capacidad para aprender dependencias basadas en un número finito de observaciones, donde el término aprendizaje significa que el conocimiento adquirido a partir de la muestra de observaciones históricas puede ser empleado para proporcionar una respuesta correcta ante datos no utilizados en el entrenamiento de la red y, por lo tanto, no conocidos por ésta. La literatura sugiere que las redes neuronales poseen varias ventajas potenciales sobre los métodos estadísticos tradicionales, destacándose el que éstas pueden ser aproximadoras de funciones universales, aun para funciones no lineales (Hornik, Stinchcombe & White, 1989), lo que significa que ellas pueden aproximar automáticamente cualquier forma funcional (lineal o no lineal) que mejor caracterice los datos, permitiéndole a la red extraer más señales a partir de formas funcionales subyacentes complejas (Hill, Márquez, O'Connor & Remus, 1994). Cabe señalar que algunos investigadores han encontrado que, en general, los mercados financieros se comportan de una forma no lineal (Bosarge, 1993), cuestión que ha favorecido el empleo de modelos de redes neuronales ya que, como se dijo anteriormente, éstas han evidenciado un buen desempeño en modelamientos no lineales (Widrow, Rumelhart & Lehr, 1994).

Es posible distinguir al menos dos importantes aplicaciones de las redes neuronales en las áreas de economía y finanzas: primero, la clasificación de

³ Cuentan con una gran cantidad de neuronas o procesadores elementales (PEs), cada uno de los cuales trabaja paralelamente con una pequeña parte de un problema mayor.

⁴ Cuentan con muchas neuronas a través de las cuales distribuyen su memoria.

⁵ Tienen la capacidad de adaptarse al entorno modificando sus pesos y sinapsis de manera de encontrar una solución aceptable al problema.

agentes económicos, por ejemplo, para obtener una estimación de la probabilidad de quiebra (Odom & Sharda, 1990; Wilson & Sharda, 1994; Rahimian et al., 1993)., segundo, la predicción de series de tiempo (Tang et al.,1991). Cabe destacar que el propósito de un modelo de predicción es capturar patrones de comportamiento en datos multivariados que distingan varios resultados, cosa que es bien realizada por los modelos no paramétricos de redes neuronales (Gorr, 1994), los cuales han sido desarrollados para predecir valores de índices bursátiles y de activos individuales, situándose la mayoría de las primeras investigaciones y aplicaciones en mercados establecidos en U.S.A. (Bosarge, 1993; Tsibouris & Zeidenberg, 1995; White, 1993), Gran Bretaña (Tsibouris & Zeidenberg, 1995) y Japón (Yoda, 1994). Dichos modelos han sido empleados para predecir el nivel o el signo de los retornos de índices bursátiles, entre otras aplicaciones relacionadas a la toma de decisiones en las áreas de finanzas e inversión (Hawley, Johnson & Raina, 1990; Refenes, 1995).

3. Metodología y Datos

Se utilizaron 283 valores de cierre semanales de las variables incluidas en el análisis, correspondientes al período comprendido entre el 14 de julio de 1997 y el 9 de diciembre de 2002.

A. Algoritmos Genéticos

El objetivo del algoritmo genético es proporcionar una metodología de búsqueda que permita encontrar un modelo multivariado dinámico que maximice el porcentaje de predicción de signo (PPS) de las variaciones semanales del IPSA. El modelo multivariado dinámico utilizado es un modelo de series de tiempo que expresa el comportamiento de una variable en función de sus valores rezagados, de rezagos de variables exógenas y de rezagos de los residuos del modelo. El modelo se basa en un algoritmo genético simple que trabaja con cadenas binarias de largo fijo en representación de las posibles soluciones al problema. La forma funcional del modelo multivariado dinámico utilizado se presenta a continuación:

(1)

$$\Delta IPSA_t = \alpha_1 \cdot \Delta IPSA_{t-1} + \dots + \alpha_{AR} \cdot \Delta IPSA_{t-AR} + \delta_1 \cdot \varepsilon_{t-1} + \dots + \delta_{MA} \cdot \varepsilon_{t-MA} + \phi_1 \cdot \Delta DJI_{t-1} + \dots + \phi_X \cdot \Delta DJI_{t-X} + \varepsilon_t$$

donde $\Delta IPSA_{t-AR}$ representa la variación del IPSA rezagada, y que corresponde

al componente autorregresivo del modelo (AR); ϵ_{t-MA} se refiere al término de error rezagado utilizado como variable independiente (MA); y ΔDJI_{t-1} es la variación del índice bursátil estadounidense Dow Jones Industry rezagada, y que construye la variable independiente de carácter exógeno (X). Los subíndices AR, MA y X representan el máximo orden de rezagos de las variables independientes - que para efectos de este estudio fue de cuatro ⁶, por lo que el modelo podría contar con un máximo de 12 variables. Cada variable fue representada con un *bit* y, por lo tanto, el largo de la cadena binaria resultó ser igual al máximo número de variables del modelo ⁷. De acuerdo a las matemáticas binarias, una cadena de largo L permite representar $2L$ soluciones posibles. En consecuencia, contamos con un total de 4.096 posibles modelos para predecir la dirección de las fluctuaciones del IPSA, entre los cuales el algoritmo genético realizará la búsqueda de la mejor solución.

Se evaluó la calidad de cada modelo en función del PPS alcanzado. La evaluación se realizó sobre la base de un conjunto extramuestral de 230 datos semanales, utilizando un proceso recursivo ⁸. Para el proceso de selección y generación de descendencia se utilizó el método *window* para asignar las probabilidades de selección a la población, usando como valor de calidad inicial el PPS, de cada modelo. El método *window* impide que el peor ejemplar de una generación sea elegido para la reproducción, otorgándole una probabilidad de selección nula debido a que el exceso de calidad sobre sí mismo es cero.

⁶ En análisis previos se obtuvo como resultado que cuando se utilizaban rezagos superiores a cuatro no aumentaba significativamente la capacidad predictiva del modelo.

⁷ El primer bit de la cadena representará al índice, en primera diferencia y rezagado en un período; el bit 2 representará al rezago 2; el bit 5 representará el residuo del modelo rezagado en un período; el bit 8 representará al cuarto rezago del residuo; el siguiente bit representará el primer rezago del DJI en primera diferencia y, finalmente, el último bit representará al cuarto rezago. Cada bit puede tomar el valor de 0 o 1: cuando tome el valor de 0, la variable que representa no será incluida en el modelo, mientras que cuando tome el valor de 1, la variable representada sí formará parte del modelo. Una vez realizada la codificación de los modelos, se comenzó a trabajar con el algoritmo genético. La primera generación de modelos (o población inicial), de un tamaño de 80, se obtuvo aleatoriamente desde el rango de interés.

⁸ La *recursividad* ha sido empleada para medir el desempeño de modelos de redes neuronales que buscan predecir períodos de recesión en los Estados Unidos (Qi, 2001; Estrella & Mishkin, 1998), y para proyectar el signo de las variaciones de índices bursátiles internacionales (Parisi, Parisi & Guerrero, 2003; Parisi, Parisi & Cornejo, 2004). De esta forma, si consideramos que el conjunto extramuestral tiene "*m*" datos, al evaluar el funcionamiento de los modelos de algoritmos genéticos o de la red, se consideró sólo la predicción del primer valor. Posteriormente, el dato analizado salió del conjunto extramuestral y pasó a formar parte del conjunto intramuestral o de entrenamiento. De esta forma, la muestra uno (de tamaño "*n*") se extiende a "*n+1*" observaciones y la muestra dos (de tamaño "*m*") se contrae a "*m-1*" datos. Luego se realizó una nueva iteración, lo que implicó re-estimar los coeficientes y los pesos de los modelos multivariados y de la red, respectivamente, en cada una de las "*m-1*" proyecciones. Esto permitió a los modelos aprender del error cometido en la predicción y ajustar nuevamente los coeficientes y pesos estimados. Este proceso se repitió una y otra vez hasta que en el conjunto extramuestral quedó un solo dato.

La selección de los padres de la nueva generación se realizó a través del método de la ruleta truncada, especificando que el 10% más apto de la generación actual se traspasará a la siguiente generación. Se seleccionaron dos cromosomas padres para que generaran dos hijos, utilizando el operador de cruce doble hasta completar el tamaño de población deseado. Se permitió que la mutación ocurriera con una probabilidad de 8.33%⁹. La clonación está implícita en el proceso ya que no se restringió el cruce entre dos modelos iguales. Una vez terminada la nueva generación de modelos se aplicó la función de calidad, continuando con el proceso de selección y generando nuevas descendencias. Este proceso finalizó al lograr 15 generaciones¹⁰.

B. Redes Neuronales

En cuanto al modelo de red neuronal, la variable de salida está dada por la variación (o primera diferencia) del IPSA correspondiente al período "t" (ΔIPSA_t), mientras que las variables de entrada se refieren a las variaciones del IPSA rezagadas y a las variaciones del índice Dow Jones Industry también rezagadas. La forma funcional del modelo se expresa en la ecuación (2):

$$\Delta\text{IPSA}_t = g(\Delta\text{IPSA}_{t-1}, \Delta\text{IPSA}_{t-4}, \Delta\text{DJI}_{t-2}, \Delta\text{DJI}_{t-3}) \quad (2)$$

La construcción de la red neuronal requiere que la base de datos se divida en dos conjuntos diferentes: (a) conjunto de entrenamiento, porción de datos empleados para que la red aprenda el problema, el cual se extiende desde el 14 de julio de 1997 hasta el 13 de julio de 1998, y (b) conjunto de producción o extramuestral, datos que no han sido incorporados anteriormente, que serán utilizados para probar el rendimiento o la capacidad de predicción de la red ante datos que nunca ha visto, y que pertenecen al subperíodo que abarca desde el 20 de julio de 1998 hasta el 9 de diciembre de 2002.

Para predecir el signo de las variaciones semanales del IPSA se empleó la *red ward* de tres capas, modelo de red neuronal que usa el algoritmo de

⁹ Esto se hace generando un número aleatorio entre 0 y 1, cada vez que se reproduce un hijo. Si el número es menor que 0,01, entonces dicho hijo muta justo antes de formar parte de la población.

¹⁰ El número de generaciones se determinó en base a información obtenida de estudios previos, en que a medida que éstas aumentan no se presentan cambios significativos en la capacidad predictiva del modelo.

aprendizaje supervisado de propagación hacia atrás. El modo de aprendizaje supervisado indica que la variación observada del índice bursátil es usada para supervisar el proceso de entrenamiento, ajustando los pesos sinápticos de la red en función del error alcanzado en este proceso ¹¹. La utilización de la *red ward* se basa en su buen desempeño con las series de tiempo, como ha sido evidenciado por Parisi (2002) y Parisi, Parisi & Guerrero (2003). Esta red se caracteriza porque pueden aplicarse diferentes funciones de activación a los *slabs* de la capa oculta, a fin de detectar diferentes características en los patrones procesados a través de la red. De esta manera, la capa de salida tendrá diferentes puntos de vista de los datos, lo cual puede conducir a una mejor predicción.

C. *Evaluación de la Capacidad Predictiva y Análisis Comparativo*

Tanto los modelos generados por algoritmos genéticos como el modelo de redes neuronales fueron construidos a partir de los datos del conjunto intramuestral. Este proceso fue seguido por una evaluación sobre la base de los datos del conjunto extramuestral, el cual se compone de 230 observaciones semanales. En esta etapa, el desempeño relativo de los modelos fue medido por el número de predicciones correctas del signo de la variación del índice. Para ello se comparó el signo de la variación proyectada con el signo de la variación observada en cada *i*-ésimo período - donde $i=1,2,\dots, m$ -. Si los signos de la proyección y el valor observado coinciden, entonces aumenta la efectividad del modelo analizado y, en caso contrario, disminuye su capacidad predictiva. Luego, al igual que Kanas (2001), se aplicó el test de precisión direccional de Pessarar y Timmermann (1992) sobre la proyección y los datos observados pertenecientes al conjunto extramuestral.

¹¹ La red aprende un conjunto predefinido de pares de entradas y salidas dadas, empleando un ciclo propagación-adaptación de dos fases: una vez que se han aplicado los datos de entrada a la primera capa de unidades de la red, ésta se va propagando a través de todas las capas superiores hasta generar una salida, la cual se compara con la salida deseada para estimar el error asociado a la predicción. El error se transmite hacia atrás, desde la capa de salida hacia todas las capas intermedias que contribuyan directamente a ella. Sin embargo, las unidades de la capa intermedia sólo reciben una fracción del error total, basándose en la contribución relativa de la unidad a la salida original. Este proceso se repite, capa por capa. Luego, basándose en el error, se actualizan los pesos de conexión de cada unidad con el objeto de ajustar el modelo y disminuir el error final. Así a medida que se entrena la red, las neuronas de las capas intermedias se organizan a sí mismas de tal modo que ellas aprenden a reconocer distintas características del conjunto de entrenamiento, aproximándose de esta manera al comportamiento de los agentes, en nuestro caso, del mercado bursátil.

Por otra parte, el mejor modelo multivariado dinámico - construido en función de algoritmos genéticos - y el modelo de red neuronal fueron comparados con un modelo *naive* o ingenuo, representado por la ecuación (3).

$$\Delta\text{IPSA}_t = \alpha_1 \cdot \Delta\text{IPSA}_{t-1} + \varepsilon_t \quad (3)$$

donde Δ indica la primera diferencia, α_1 es el coeficiente que acompaña a la variable explicativa, y ε_t representa el término de error en el momento "t". Sin embargo, Sharda (1994) señala que los resultados basados en tal comparación están sujetos a una muestra sesgada, lo que atenta contra su significancia estadística. Por esta razón y con el objetivo de evitar el problema de *data snooping*¹² y de despejar las dudas respecto de si la capacidad predictiva se debe a la bondad del modelo, a las características de la muestra de observaciones sobre la que ha sido aplicado, o simplemente al factor suerte se utilizó la metodología de *block bootstrap*¹³, la que permitió crear 60 nuevas series de datos extramuestrales a partir del conjunto original de observaciones. Debido a que estamos trabajando con variaciones semanales, el largo fijo del *block bootstrap* usado en este estudio fue de 4 observaciones, a fin de mantener la correlación que puedan registrar las fluctuaciones semanales del IPSA a lo largo de un mes. En consecuencia, el PPS y el test de Pessaran & Timmermann fue calculado para los modelos generados por el algoritmo genético, el modelo de red neuronal y el modelo *naive*, en cada uno de los 60 conjuntos extramuestrales creados a partir del método *block bootstrap*, además de la serie original, con el objetivo de darle robustez a los resultados y a las conclusiones del estudio.

¹² El término *data snooping* (también conocido como *data mining*), "ocurre cuando un determinado conjunto de datos es usado más de una vez para propósitos de inferencia o selección de modelos. Cuando esta reutilización de datos ocurre, siempre existe la posibilidad de que cualquier resultado satisfactorio que se haya obtenido pueda deberse simplemente a la suerte, en vez de a algún mérito inherente al modelo que generó aquellos resultados." (White, 2000).

¹³ Una forma de probar la bondad de los modelos y la validez de sus resultados, independientemente de la muestra de datos sobre las que han sido aplicados, es usar un proceso de *bootstrap*. El *bootstrap* es un proceso de generación de observaciones ficticias a partir de datos históricos, a fin de dar solución al problema de escasez de datos y, de esta forma, poder contar con suficiente información para elaborar diferentes conjuntos extramuestrales sobre los cuales probar la validez de los modelos. El *bootstrap* consiste en seleccionar y ordenar, una a una y de manera aleatoria, las observaciones que forman parte del conjunto extramuestral inicial para construir de manera artificial una nueva serie de datos. Sin embargo, es posible que al seleccionar y ordenar de manera aleatoria las observaciones para efectos de construir un nuevo conjunto extramuestral se pierda la correlación de los datos y la serie, en consecuencia, carezca de sentido. El *block-bootstrap* se plantea como una solución a este problema ya que, si bien también selecciona y ordena las observaciones del conjunto original para general uno nuevo, no lo hace una por una sino que toma bloques fijos de datos diarios o semanales, con el objetivo de rescatar la relación que podría existir entre las observaciones diarias a lo largo de una semana, o de las observaciones semanales durante el transcurso de un mes.

Por último, se aplicaron los test de Friedman y de Tukey, los cuales permitieron determinar, por una parte, la existencia o no de diferencias significativas entre el PPS de los modelos y, por otra, la existencia o no de diferencias significativas entre los retornos generados por ellos.

4. Análisis de resultados

Al analizar la serie de valores de cierre, en primera diferencia, del índice bursátil chileno IPSA (ver cuadro N°1) se encontró que los resultados del test de Jarque-Bera rechazan la hipótesis de que las variaciones semanales de este índice siguen una distribución normal, con un nivel de significancia del 5%. Además, el coeficiente de autocorrelación para un modelo AR(1) resultó ser estadísticamente significativo, a un nivel de significancia del 10%, por lo que se encontró evidencia de autocorrelación entre la variación experimentada por el índice en el período “*t*” y la registrada en el período “*t-1*”. Finalmente, los test de Wald-Wolfowitz (de corridas) y Cox-Stuart (de signos no ponderados) no presentan evidencia concluyente sobre la presencia de aleatoriedad en la serie de variaciones del índice accionario ¹⁴.

El mejor modelo multivariado dinámico, en términos de PPS, obtenido a través del algoritmo genético, presenta la siguiente forma funcional:

(4)

$$\Delta\text{IPSA}_t = \alpha_1 \cdot \Delta\text{IPSA}_{t-4} + \delta_1 \cdot \varepsilon_{t-1} + \delta_2 \cdot \varepsilon_{t-4} + \phi_1 \cdot \Delta\text{DJI}_{t-2} + \phi_2 \cdot \Delta\text{DJI}_{t-3} + \varepsilon_t$$

Como se observa en el cuadro N° 2, la *red ward* superó en capacidad predictiva al modelo multivariado dinámico construido a través de algoritmos genéticos y al modelo *naive* (sus PPS fueron de 69,13%, 61,30% y 53,48%, respectivamente). Por su parte, los resultados del test de Pessaran & Timmermann permiten concluir que la capacidad predictiva del modelo de algoritmos genéticos y de la *red ward* es significativa en términos estadísticos. En el caso del modelo *naive* no se rechazó la hipótesis nula, por lo que se concluyó que no presenta capacidad para predecir el signo de las fluctuaciones semanales del IPSA.

¹⁴ El test de Wald-Wolfowitz rechaza la hipótesis nula de aleatoriedad, con un nivel de significancia de 10%. Sin embargo, según el test de Cox-Stuart no se rechaza la hipótesis nula.

A continuación se analizó si la capacidad predictiva evidenciada por los modelos se traduce o no en mayores beneficios económicos. Para ello se calculó la rentabilidad acumulada durante el período de análisis que hubiera logrado un inversionista de haber seguido las recomendaciones de compra-venta de estos modelos, asumiendo una inversión inicial de \$ 10.000.000¹⁵ y que el IPSA puede ser transado como si fuera una acción. Al momento de calcular la rentabilidad de la estrategia de transacción, basada en las proyecciones de cada uno de los modelos analizados, se consideró un costo de 0,1% por transacción¹⁶, el cual se aplicó sobre el monto de dinero transado. Cabe señalar que, para que un modelo predictivo o un indicador de análisis técnico desempeñe su función, éste debe producir un retorno que exceda la suma de los costos de transacción más la rentabilidad negativa originada por sus señales falsas. También se calculó la rentabilidad generada por la estrategia en una situación en la cual el costo de transacción es fijo y asciende a US\$ 9¹⁷ (independientemente del volumen transado), y el monto de inversión inicial es de US\$ 10.000¹⁸. No se realizaron ventas cortas. Los resultados muestran que, considerando un costo de transacción de 0,1%, la *red ward recursiva* logró una rentabilidad acumulada de 118,03%, la más alta dentro de los modelos analizados. Por su parte, el modelo de algoritmos genéticos alcanzó una rentabilidad acumulada de 46,61%, mientras que el modelo *naive* logró un retorno acumulado de 10,06%, superior al que habría generado una estrategia de inversión pasiva o *buy and hold*¹⁹ (1,19%).

¹⁵ La inversión inicial es de \$10.000.000. Por lo tanto, no se pueden adquirir más unidades del índice que las que permite la inversión inicial, aun cuando el modelo de proyección siga recomendando "comprar". De igual manera, sólo puede venderse aquello que ha sido comprado.

¹⁶ En el mercado bursátil chileno, el costo de transacción es un porcentaje fijo que se aplica sobre el monto de dinero involucrado en la transacción. Este costo de transacción involucra una comisión por los derechos que cobra la Bolsa de Valores de Santiago de Chile (que asciende al 0,05%) y una comisión que cobra el corredor (*trader*). El costo de transacción varía desde los pequeños a los grandes inversionistas, ya que estos últimos tienen un mayor poder de negociación. Así, por ejemplo, en el mercado bursátil chileno existen inversionistas institucionales (Administradoras de Fondos de Pensiones, Administradoras de Fondos Mutuos y Compañías de Seguros) que enfrentan un costo por transacción equivalente al 0,1% del monto de dinero involucrado en la operación, más I.V.A. (Impuesto al Valor Agregado). Debido a que las empresas de servicios traspasan el pago del I.V.A. a sus clientes (por lo que no es un costo para la empresa), al momento de calcular la rentabilidad de la estrategia de transacción basada en las proyecciones de cada uno de los modelos analizados, se consideró un costo de 0,1% por transacción.

¹⁷ El costo de transacción en el mercado bursátil estadounidense es fijo, a diferencia del costo de transacción del mercado accionario chileno que es variable y corresponde a un porcentaje del monto transado. El costo de transacción del mercado estadounidense depende del *broker* utilizado, y puede fluctuar entre US\$ 7 y US\$ 20 por transacción. Para los fines de este estudio, se consideró un costo de US\$ 9 por transacción.

¹⁸ Para realizar este cálculo se asumió que el valor de cierre del IPSA estaba expresado en dólares estadounidenses.

¹⁹ La estrategia "*buy and hold*" es una estrategia de inversión pasiva que no aplica gestión alguna. Consiste en comprar el activo en cuestión y mantenerlo durante todo el periodo de inversión, para venderlo al final de éste. La rentabilidad de esta estrategia está dada por la diferencia entre el valor de venta y el valor de compra del activo analizado.

Los modelos analizados también fueron evaluados en las 60 series generadas por medio del proceso *block-bootstrap*. El cuadro N° 3 muestra el promedio, la mediana, el mínimo, el máximo y la desviación estándar calculada sobre el PPS de las 60 series *bootstrap*, correspondiente a los modelos analizados. Se observa que la *red ward* registró el PPS promedio más alto (un 74,93%) en comparación con el PPS del modelo de algoritmos genéticos y del modelo *naive* (53,41% y 54,80%, respectivamente). Con respecto a la capacidad predictiva, ésta resultó ser estadísticamente significativa para la *red ward* en las 60 series *bootstrap*, de acuerdo al test de Pessaran & Timmerman. La capacidad predictiva del modelo de algoritmos genéticos fue significativa sólo en el 15% de las series, mientras que el modelo *naive* lo fue en el 22%. El nivel de confianza asociado al testeo de hipótesis fue de un 95%.

Por otro lado, la rentabilidad acumulada promedio que se obtuvo al comprar-vender el IPSA siguiendo las recomendaciones de la *red ward* fue la más alta (25,42%). El modelo de algoritmos genéticos y el modelo *naive* generaron una rentabilidad acumulada promedio de 5,29% y 5,07%, respectivamente. Por otra parte, la estrategia *buy and hold* mostró resultados más discretos en comparación con los modelos predictivos analizados, alcanzando una rentabilidad acumulada promedio de -5,33%. En cuanto a la rentabilidad mínima registrada por la *red ward*, ésta fue de -1,75%. En consecuencia, los resultados señalan que la *red ward* tendría mayor capacidad que el modelo de algoritmos genéticos y el modelo *naive* para predecir el signo de las variaciones del IPSA, que esta capacidad predictiva sería estadísticamente significativa, y que una estrategia de transacción basada en las señales de compra-venta dadas por el modelo permitirían obtener retornos relativamente más altos. Finalmente destacamos que los modelos superaron, en promedio, los resultados de la estrategia de inversión pasiva o *buy and hold*, aun cuando se consideró un costo por transacción equivalente al 0,1% del monto transado. También se destaca que, dados los resultados de las series *bootstrap*, las técnicas no sólo lograron incrementar la rentabilidad promedio de la inversión sino que también permitieron reducir la variabilidad de los retornos, disminuyendo con ello las pérdidas y el riesgo asociado a la inversión.

El cuadro N° 5 muestra los resultados de los modelos en términos de rentabilidad, pero considerando en esta ocasión un costo fijo de US\$ 9 por transacción. En términos generales, las conclusiones derivadas del análisis del cuadro N° 4 se mantienen, excepto para el modelo *naive* que, en este escenario

de costos de transacción, registró el peor desempeño en materia de rentabilidad, siendo superado incluso por la estrategia *buy and hold*. Se destaca que las rentabilidades logradas por las estrategias de *trading* son superiores en el caso en que el costo de transacción es fijo (US\$ 9). De esta manera, el análisis de *bootstrap* confirma las conclusiones obtenidas a partir de los resultados del cuadro N° 2.

Los resultados del test de Friedman (cuadro N° 6) nos indican que existen diferencias estadísticamente significativas entre los PPS y los retornos anormales generados por los modelos analizados. De manera más específica, el test de Tukey señala que no hay diferencias significativas entre el modelo de algoritmos genéticos y el modelo *naive* en términos de PPS y retorno anormal, pero sí las hay entre los resultados de estas técnicas y los de la *red ward*.

5. Conclusiones

La *red ward* superó en capacidad predictiva al modelo multivariado dinámico construido a través de algoritmos genéticos y al modelo *naive* (sus PPS fueron de 69,13%, 61,30% y 53,48%, respectivamente). Por su parte, los resultados del test de Pessaran & Timmermann permiten concluir que la capacidad predictiva del modelo de algoritmos genéticos y de la *red ward* es significativa en términos estadísticos. En el caso del modelo *naive* no se rechazó la hipótesis nula, por lo que se concluyó que no presenta capacidad para predecir el signo de las fluctuaciones semanales del IPSA. Además, los resultados muestran que la *red ward recursiva* logró una rentabilidad acumulada de 118,03%, la más alta dentro de los modelos analizados. Por su parte, el modelo de algoritmos genéticos alcanzó una rentabilidad acumulada de 46,61%, mientras que el modelo *naive* logró un retorno acumulado de 10,06%, superior al que habría generado una estrategia de inversión pasiva o *buy and hold*²⁰ (1,19%).

Los modelos analizados también fueron evaluados en las 60 series generadas por medio del proceso *block-bootstrap*. Los resultados señalan que la *red ward* tendría mayor capacidad que el modelo de algoritmos genéticos y el modelo *naive* para predecir las variaciones del IPSA, que esta capacidad

²⁰ La estrategia "*buy and hold*" es una estrategia de inversión pasiva que no aplica gestión alguna. Consiste en comprar el activo en cuestión y mantenerlo durante todo el período de inversión, para venderlo al final de éste. La rentabilidad de esta estrategia está dada por la diferencia entre el valor de venta y el valor de compra del activo analizado.

predictiva sería estadísticamente significativa, y que una estrategia de transacción basada en las señales de compra-venta dadas por este modelo permitirían obtener retornos relativamente más altos. Finalmente destacamos que la *red ward* y el modelo de algoritmos genéticos superaron, en promedio, los resultados de la estrategia de inversión pasiva o *buy and hold*, aun cuando se consideró un costo por transacción equivalente al 0,1% del monto transado en cada operación de compra-venta, simulando el caso chileno, y de US\$ 9, para analizar el caso estadounidense.

De esta forma, se mostró que la capacidad de los modelos de redes neuronales y de algoritmos genéticos podría resultar relevante para predecir el signo de las variaciones del IPSA chileno, lo que los sitúa como una alternativa al análisis técnico y a los modelos *naive* aplicados sobre series de tiempo al momento de predecir la evolución del mercado para tomar decisiones de inversión o desinversión en activos bursátiles. Sin embargo, es posible mejorar la aplicación del algoritmo genético a fin de optimizar los resultados, tanto a nivel de capacidad predictiva como de rentabilidad de la inversión, cuestión que será abordada en estudios posteriores.

REFERENCIAS

- AGGARWAL, R. & DEMASKEY, A. (1997). Using derivatives in major currencies for cross-hedging currency risks in Asian emerging markets. *Journal of Futures Markets*, V.17, Issue 7, 781, 16.
- ALLEN, F. & KARJALAINEN, R. (1999). Using genetic algorithms to find technical trading rules. *Journal of Financial Economics*, 51, 245-271.
- BAUER, RICHARD J. JR. (1994). *Genetic Algorithms and Investment Strategies*, John Wiley & Sons, Inc.
- BLUME, L., EASLEY D. & O'HARA M. (1994). Market statistics and technical analysis: The role of volume. *Journal of Finance* 49, 153-82.
- BOSARGE, W.E. (1993). Adaptive processes to exploit the nonlinear structure of financial markets. In R.R. Trippi & E. Turban (eds.),

Neural networks in finance and investing. New York, Irwin, 371-402.

CHOPRA, N., LAKONISHOK J. & RITTER J. R. (1992). Measuring abnormal returns: Do stocks overreact? *Journal of Financial Economics* 31,235-268.

CONRAD J. & KAUL G. (1988). Time-variation in expected returns. *Journal of Business* 61,409-425.

CONRAD J. & KAUL G. (1989). Mean reversion in short-horizon expected returns. *Review of Financial Studies* 2,225-240.

DAVIS, LAWRENCE. (1994). Genetic Algorithms and Financial Applications, in: *Deboeck (ed., 1994)*,133-147.

DEBONDT, W. F. M. & THALER R. (1985). Does the stock market overreact? *Journal of Finance* 40,793-805.

ESTRELLA, A., & MISHKIN, F. S. (1998). Predicting US recessions: Financial variables as leading indicators. *The Review of Economics and Statistics* 80(1),45-61.

FAMA, EUGENE (1970). Efficient capital markets: A review of theory and empirical work". *Journal of Finance* 25, 383-417.

FAMA, E. & FRENCH K. R. (1988). Permanent and temporary components of stock prices. *Journal of Political Economy* 98,247-273.

FELDMAN, K. & TRELEAVEN, P. (1994). Intelligent systems in finance. *Appl. Mathematical Finance* 1,195-207, Chapman & Hall, London, UK.

GORR WILPEN L. (1994). Research prospective on neural network fore casting. *International Journal of Forecasting* (10)1,1-4.

HAWLEY, D., JOHNSON, J., & RAJNA, D. (1990). Artificial neural systems: A new tool for financial decision-making. *Financial Analysts Journal* 23, 60-72.

- HERBRICH, R., KEILBACH, M., GRAEPEL, T., BOLLMANN-SDORRA, P. & OBERMAYER K. (2000). "Neural networks in economics: Background, applications and new developments". In T. Brenner, editor, *Advances in Computational Economics: Computational Techniques for Modelling Learning in Economics*, volume 11, pages 169-196. Kluwer Academics.
- HILL, T., MARQUEZ, L., O'CONNOR, M. & REMUS, W. (1994). Artificial neural network models for forecasting and decision making. *International Journal of Forecasting* (10)1,5-15.
- HODGSON, A. & NICHOLLS, D. (1991). The impact of index futures markets on Australian share market volatility. *Journal of Business Finance and Accounting* 18,267-280.
- HOLLAND, JOHN H. (1975). *Adaptation in Natural and Artificial Systems*, The University of Michigan Press. Ann Arbor.
- HORNIK, K., STINCHCOMBE M. & WHITE H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5),359-366.
- JEGADEESH, NARASIMHAN (1990). Evidence of predictable behavior of security returns. *The Journal of Finance*, Vol. 45(3),881-898 (July).
- KANAS, ANGELOS (2001). "Neural networks linear forecasts for stocks returns". *International Journal of Finance and Economics*,6,245-254.
- KIM, K. & HAN, I. (2000). Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. *Expert Systems with Applications*,vol 19,Nº2,Agosto,125-132.
- KINGDON, J. & FELDMAN, K. (1995). Genetic algorithms and applications to finance. *Applied Mathematical Finance*,vol 2, Nº 2, Junio,89-116.
- KUO, C. & REITSCH A. (WINTER 1995-96). "Neural networks vs. conventional methods of forecasting", *Journal of Business Forecasting* 14, Nº4, 17-22.

- LEUNG MARK T., DAOUK HAZEM, CHEN AN-SING (2000). "Forecasting stock indices: a comparison of classification and level estimation models". *International Journal of Forecasting* (16) 2,173-190.
- LO, A. & MAC KINLEY A. C. (1988). Stock market price do not follow random walk: Evidence from a simple specification test. *Review of Financial Studies* 1, 41-66.
- MABERLY, E. D. (1986). The informational content of the interday price change with respect to stock index futures. *Journal of Futures Markets* 6, 385-395.
- MARTÍN DEL BRÍO, B. & SANZ, A. (1997). Redes neuronales y sistemas borrosos: Introducción, teórica y práctica. Primera Edición. *Ra-ma*. 387.
- O'Connor, M., Remus, W., & Griggs, K. (1997). Going up-going down: How good are people at forecasting trends and changes in trends? *Journal of Forecasting* 16,165-176.
- ODOM M. D. & SHARDA R. (1990). A neural network model for bankruptcy prediction. Proceedings of the IEEE International Conference on Neural Networks, San Diego II,160-168.
- PARISI, A. (2002). Evaluación de modelos de Redes Neuronales de predicción del signo de la variación del IPSA. *Estudios de Administración*, vol. 9, N°1,67- 103. Chile.
- PARISI, A., F. PARISI & J. L. GUERRERO (2003). Modelos predictivos de Redes Neuronales en índices bursátiles internacionales. *El Trimestre Económico*, N° 280, vol. LLX (4), 721- 744. México.
- PARISI, A., PARISI, F. & GUERRERO, J. L. (2003). "Modelos Predictivos de Redes Neuronales en Indices Bursátiles", *El Trimestre Económico*, México. (Forthcoming).
- PEREIRA, ROBERT. (1996). Selecting parameters for technical trading rules using genetic algorithms, *Journal of Applied Finance and Investment*, Volume 1, No. 3, July/August. 27-34.

- PESSARAN, M.H. & TIMMERMANN A. (1992). A simple nonparametric test of predictive performance. *Journal of Business and Economic Statistics* 10, 461-465.
- POTERBA, J. M. & SUMMERS L. H. (1988). Mean reversion in stock prices: Evidence and implications. *Journal of Financial Economics* 22, 27-59.
- QI, MIN (2001). Predicting US recessions with leading indicators via neural network models. *International Journal of Forecasting* (17) 3,383-401.
- RAHIMIAN E., SINGH S., THAMMACHOTE T. & VIRMANI R. (1993). Bankruptcy prediction by neural network. In: R. R. Trippi & E. Turban (eds.): *Neural networks in finance and investing. Probus Publishing*, 159-171.
- REFENES, A. P. (1995). *Neural networks in the capital markets*, Wiley, New York.
- SHARDA, R. (1994). *Neural networks for the MS/OR analysis: An application bibliography*. *Interfaces*, 24, 116-130.
- TANG, Z., DE ALMIEDA C. & FISHWICK P. (1991). Time-series forecasting using neural networks vs. Box-Jenkins methodology. *Simulation*, 57(5), 303-310.
- TSIBOURIS, G. & ZEIDENBERG, M. (1995). Testing the efficient markets hypothesis with gradient descent algorithms. In A.P. Refenes (ed.). *Neural networks in the capital markets*. Chichester, UK, Wiley, 127-136.
- WHITE, H. (1993). Economic prediction using neural networks: the case of IBM daily stock returns. In R.R. Trippi & E. Turban (eds.). *Neural networks in finance and investing*. New York, Irwin, 315-328.

- WHITE, H. (2000). "A reality check for data snooping". *Econometría*, Vol. 68, Nº 5, 1097-1126.
- WIDROW, B., RUMELHART, D.E. & LEHR, M.A. (1994). Neural networks: Applications in industry, business and science *Communications of the ACM*, 37, 3 (March), 93-105.
- WILSON, R. L. & SHARDA R. (1994). Bankruptcy prediction using neural networks. *Decision Support Systems*, 11(5), June, 545-557.
- WU, Y., & ZHANG, H. (1997). Forward premiums as unbiased predictors of future currency depreciation: A non-parametric analysis. *Journal of International Money and Finance* 16, 609-623.
- YODA, M. (1994). Predicting the Tokyo stock market. In G.J. Deboeck (ed.), *Trading on the edge: Neural, genetic, and the fuzzy systems for chaotic financial markets*. New York, Wiley, 66-67.

Cuadro N° 1

Estadística Descriptiva

Estadísticos descriptivos para las series de valores de cierre semanales, en primera diferencia, del índice de Precios Selectivo de Acciones (IPSA) del mercado bursátil chileno. Entre paréntesis se entrega el test *t*. El período de estudio abarca desde el 14 de julio de 1997 hasta el 9 de diciembre de 2002 (283 observaciones).

Estadísticos	IPSA
Media	-0,115
Mediana	-0,097
Máximo	11,029
Mínimo	-14,916
Desviación Estándar	3,903
Skewness	-0,215
Kurtosis	4,027
Jarque-Bera ¹	14,825*
AR(1) ¹	0,113 (1,917)**
Wald-Wolfowitz ²	-1,713**
Cox-Stuart ²	-0,585

¹ Los valores críticos de los estadísticos Jarque-Bera y *t* de Student son 4,43 y 1,96, respectivamente, para un $\alpha=5\%$.

² Los valores críticos de los estadísticos Wald-Wolfowitz y Cox-Stuart son 1,96 y 1,64, para un nivel de significancia del 5% y 10%, respectivamente.

(*) Significativo al 5%. (**) Significativo al 10%.

Cuadro N° 2

Resultados de los modelos

Modelo	PPS	Test DA ¹	Retorno ²	Retorno ³
Red Ward	69,13%	5,81*	118,03%	126,21%
Algoritmo Genético	61,30%	3,43*	46,61%	50,81%
Modelo Naive	53,48%	1,04	10,06%	12,79%
Buy & Hold	-	-	1,19%	1,22%

¹ El valor de z crítico es de 1,96, para un nivel de significancia del 5%.

² Considerando un costo de 0,1% por transacción, aplicado sobre el monto de dinero transado.

³ Considerando un costo de US\$ 9 por transacción.

(*) Significativo al 5%.

Cuadro N° 3

Estadísticos calculados sobre los resultados de los 60 conjuntos extramuestrales generados por *bootstrap*. Porcentaje de Predicción de Signo.

Modelo	PPS Promedio	PPS Mediana	PPS Mínimo	PPS Máximo	PPS Desv. N° Estándar	Test DA Series ¹
Red Ward	64,93%	65,54%	55,65%	75,22%	4,31%	60
Algoritmo Genético	53,41%	53,48%	43,91%	59,57%	3,60%	9
Modelo Naive	54,80%	54,78%	47,39%	64,35%	3,46%	13

¹ Número de series *bootstrap* en las cuales los resultados de los modelos fueron significativos con un 95% de confianza.

Cuadro N° 4

Estadísticos calculados sobre los resultados de los 60 conjuntos extramuestrales generadas por *bootstrap*. Para calcular el retorno de la estrategia se consideró un costo de 0,1% por transacción.

Modelo	Promedio	Mediana	Mínimo	Máximo	Desviación Estándar
Red Ward	25,42%	25,35%	-1,75%	45,85%	20,50%
Algoritmo Genético	5,29%	4,28%	-54,86%	59,57%	25,64%
Modelo Naive	5,07%	7,08%	-61,65%	82,53%	25,55%
Buy and Hold	-5,33%	0,71%	-94,92%	66,07%	36,18%

Cuadro N° 5

Estadísticos calculados sobre los resultados de los 60 conjuntos extramuestrales generadas por *bootstrap*. Para calcular el retorno de la estrategia se consideró un costo de US\$ 9 por transacción

Modelo	Promedio	Mediana	Mínimo	Máximo	Desviación Estándar
Red Ward	28.53%	24.57%	-2,.01%	54,38%	22.57%
Algoritmo Genético	6.68%	5.65%	-56.12%	66.48%	27.02%
Modelo Naive	-17.69%	-0.30%	-119.74%	50.98%	52.60%
Buy and Hold	-5.31%	0.73%	-95.00%	66.16%	36.22%

Cuadro N° 6

Test de Tukey y Test de Friedman. Análisis de las diferencias entre el PPS alcanzado por las técnicas y entre los retornos anormales ¹. H_0 : No diferencias entre los grupos. Nivel de significancia del 5%.

PPS	Friedman Test	P-Value
AG-Red Ward-Naive	171,000	0,000
Retorno Anormal	Friedman Test	P-Value
AG-Red Ward-Naive	32,89	0,000
Tukey Test		
PPS	P-Value	
AG-Naive	0,291	
AG-Red Ward	0,000	
Red Ward-Naive	0,000	
Retorno Anormal	P-Value	
AG-Naive	1,000	
AG-Red Ward	0,000	
Red Ward-Naive	0,000	

¹Los retornos anormales han sido calculados como la diferencia entre la rentabilidad del modelo predictivo y la rentabilidad de la estrategia *buy and hold*.

Para el caso del PPS y del retorno anormal, el valor crítico de c^2 fue de 19,48, para 59 grados de libertad en el numerador, 2 grados de libertad en el denominador y un nivel de significancia de 0,05. El nivel de significancia, con el cual es comparado el *p-value* es de 0,05.

Copyright of *Estudios de Administración* is the property of Estudios de Administracion and its content may not be copied or emailed to multiple sites or posted to a listserv without the copyright holder's express written permission. However, users may print, download, or email articles for individual use.