



UNIVERSIDAD DE CHILE
Facultad de Economía y Negocios
Escuela de Economía y Administración

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los
componentes del Dow Jones Industrial Average Index

Seminario para optar al título de Ingeniero Comercial Mención Administración

Ariel Enrique Márquez Sepúlveda

Profesores guías

Dr. Antonino Parisi Fernández

David Díaz Solís

Santiago de Chile. 15 de Diciembre de 2006

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

Extracto

En este trabajo se hace una primera aproximación del concepto de conciencia a las redes neuronales utilizadas para la predicción de signo de cambios de precios en activos financieros. Se encuentra que adicionando a las redes neuronales características de conciencia se obtienen resultados significativos tanto en términos estadísticos como en términos económicos.

Se modelaron las treinta acciones que componen el principal índice accionario mundial: el Dow Jones Industrial Average Index. Se encontró que para el 100% de los activos en estudio las redes neuronales con rasgos de conciencia logran hallar al menos un modelo con capacidad predictiva de signo estadísticamente significativa que permite superar las rentabilidades de una estrategia pasiva *buy and hold* y de una estrategia *naïve* o ingenua.

**Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index**

Tabla de Contenidos

EXTRACTO.....	2
TABLA DE CONTENIDOS.....	3
I. INTRODUCCIÓN	4
II. REVISIÓN BIBLIOGRÁFICA	7
A. LAS REDES NEURONALES.....	10
B. APLICACIONES DE LOS MODELOS DE REDES NEURONALES.....	11
C. LA CONCIENCIA DESDE UNA PERSPECTIVA NO FINANCIERA	13
III. METODOLOGÍA.....	17
A. DATOS.....	17
B. VARIABLES	18
C. SOFTWARE	18
D. APLICACIÓN DEL CONCEPTO DE CONCIENCIA EN LAS REDES NEURONALES	19
E. ALGORITMOS GENÉTICOS Y LA IMPLEMENTACIÓN DEL CONCEPTO DE CONCIENCIA.....	20
F. ARQUITECTURA DE LAS REDES NEURONALES	22
G. FUNCIONES DE TRANSFERENCIA Y OTRAS CARACTERÍSTICAS	24
H. EVALUACIÓN DE LA CAPACIDAD PREDICTIVA DE LAS REDES NEURONALES Y ANÁLISIS COMPARATIVO ...	25
IV. SIMULACIÓN Y ANÁLISIS DE LOS RESULTADOS	27
V. CONCLUSIONES	33
REFERENCIAS BIBLIOGRÁFICAS.....	34
ANEXO	39

**Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index**

I. Introducción

Las redes neuronales son, en esencia, sistemas de procesamiento paralelo que replican el funcionamiento del cerebro humano para resolver problemas complejos. Estos sistemas están compuestos de elementos simples que interactúan entre sí a través de un proceso de excitación e inhibición, que en la naturaleza está generado por impulsos eléctricos, pero que en inteligencia artificial está representado por algoritmos de optimización.

Como se revisa en las secciones posteriores, existen diversas aplicaciones en el ámbito de las finanzas de estos sistemas. Un lugar importante dentro de estas aplicaciones está reservado a la predicción de precios de activos financieros, puesto que sus resultados¹ tienden a echar por tierra algunas de las teorías financieras más importantes del siglo veinte, tales como los postulados de Fama (1970) acerca de mercados eficientes.

En este estudio se discute y muestra la viabilidad de introducir algunas de las características más elementales de la conciencia humana en los modelos de redes neuronales artificiales utilizados en la predicción de signo de los cambios de precios accionarios semanales. Para analizar los resultados se evaluará la capacidad de los modelos de redes neuronales con rasgos de conciencia para predecir el signo de la variación semanal de cada una de las acciones que componen el Dow Jones Industrial Average Index (^DJI).

En este trabajo se presenta el concepto de conciencia en los sistemas redes neuronales como un proceso de optimización de la arquitectura que utilizan estos modelos para entrenarse, suponiendo que las redes se desempeñarían mejor cuando se “piensan a si mismas” que cuando es el hombre “el que piensa por ellas”.

¹ Ver, por ejemplo, Parisi, A., Parisi, F. & Guerrero, J.L. (2003), “Modelos Predictivos de Redes Neuronales en Índices Bursátiles”, *El Trimestre Económico*, México.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

Uno de los aportes que hace este estudio es mostrar que es beneficioso para los profesionales y estudiosos las finanzas adentrarse en los problemas más complejos que enfrenta la sociedad desde el punto de vista del conocimiento y tratar de entenderlos, por cuanto en las discusiones entorno a esos problemas hay una importante fuente de información que puede ser utilizada para dar solución a los dilemas del área financiera.

Prueba de lo anterior es que en este trabajo se evidencia que las redes neuronales con rasgos de conciencia, un concepto aparentemente complicado para los financistas, tienen capacidad estadísticamente significativa de predicción de signo del cambio de precio semanal en cada una de las acciones que componen el índice Dow Jones. Esto se traduce en resultados económicos significativamente mayores al seguir las proyecciones entregadas por estos modelos versus optar por una estrategia de inversión pasiva o seguir las predicciones de un modelo ingenuo, representado este último por un modelo auto regresivo de primer orden.

Entre los resultados más importantes de este trabajo encontramos que las redes neuronales con rasgos de conciencia hayan para todas las acciones componentes del Índice Dow Jones al menos un modelo con capacidad estadísticamente significativa para predecir signo de cambio de precios. Dentro de estos modelos destaca el 64,89% de capacidad predictiva encontrada por la mejor red neuronal para la acción de Coca-Cola, la cual permite generar una rentabilidad del 13,24% en el período extramuestral del estudio y que es superior en casi un 20% a la generada por la estrategia de Buy and Hold y a la que se obtiene con la estrategia ingenua.

El documento se divide en cinco secciones: la sección dos presenta una revisión de la literatura relacionada a este estudio, la sección tres explica la metodología empleada en la

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

investigación; la sección cuatro aborda la simulación y el análisis de los resultados y, finalmente, la sección cinco presenta las conclusiones del estudio.

II. Revisión bibliográfica

Lo & MacKinlay (1988), empleando datos de mercados bursátiles desarrollados tales como USA., Europa Occidental y Japón, concluyen 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. Lo anterior se contrapone con la *hipótesis de mercados eficientes* (Fama, 1970), donde la eficiencia significa que el mercado refleja completa y correctamente toda la información relevante para la determinación de los precios de los activos. Esta hipótesis, por lo general, no es aceptada y, en consecuencia, se ha intentado emplear modelos no lineales para mejorar el ajuste y la predicción de la rentabilidad de los activos bursátiles. Al hallazgo de Lo & MacKinlay (1988), quienes registran una correlación serial positiva entre los retornos semanales, se añaden los resultados de DeBondt & Thaler (1985), Fama & French (1988), Poterba & Summers (1988) y Chopra, Lakonishok & Ritter (1992), quienes encuentran una correlación serial negativa en los retornos de los activos individuales y varios portafolios, sobre intervalos de tres a diez años. En este contexto, Jegadeesh (1990) examina la predictibilidad de los retornos mensuales sobre activos individuales y encuentra una correlación serial negativa de primer orden altamente significativa para rezagos de dos meses y una correlación serial positiva para rezagos mayores.

Al momento de explicar las predictibilidad de las variaciones de los retornos accionarios se postulan dos argumentos alternativos:

- a. Los mercados son ineficientes y los precios de los activos se mueven alrededor de su valor fundamental, y

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

- b. los mercados son eficientes y la predictibilidad de las variaciones puede ser explicada por un equilibrio en los retornos time-varying.

Al respecto, Ferson & Harvey (1991) muestran que la predictibilidad de los retornos accionarios no se debe necesariamente a ineficiencias del mercado o a una sobre-reacción de los inversionistas irracionales, sino que a la predictibilidad que presentan algunas variables agregadas que son parte del set de información que explica la rentabilidad de los activos. En este sentido, un estudio de eventos de transacciones de insiders de Ferson & Schadt (1996), muestra que la omisión de variables tales como rezagos del retorno accionario y de la tasa de interés podrían conducir a resultados erróneos en la proyección. Además, 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 bien 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, cuestión que es relevante ya que una estimación puntual relativamente exacta puede no ser un buen predictor de la dirección del cambio que experimentará el nivel de precios del instrumento.

Estudios recientes han sugerido que las estrategias de transacción basadas en proyecciones de la dirección del cambio en el nivel de precios son más efectivas y pueden generar beneficios más altos que aquellas basadas en una predicción puntual del nivel de precios de los instrumentos financieros. En esta línea de estudio, 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

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

interdía e intradía, y O'Connor, Remus & Griggs (1997) concluyeron que los individuos muestran diferentes tendencias y comportamientos para series que se mueven al alza y a la baja, junto con demostrar la utilidad de proyectar la dirección del cambio en el nivel de precios.

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. En esta materia, Leung, Daouk & Chen (2000) compararon la capacidad predictiva de los modelos de clasificación (linear discriminant analysis, logit model, probit model y probabilistic neural network) con los de estimación de nivel (adaptive exponential smoothing, vector autoregression with Kalman filter, multivariate transfer function y multilayered feedforward neural network) y concluyeron que los primeros (los cuales son propuestos para predecir el signo o la dirección del retorno de los índices bursátiles S&P 500, FTSE 100 y Nikkei 225) 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 más altos. 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 en vez de minimizar la desviación de las estimaciones de los valores observados.

**Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index**

A. Las redes neuronales

De acuerdo a Martín del Brío y Sanz (1997), las redes neuronales artificiales² (R.N.A.) “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 *paralelos* (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), *distribuidos* (cuentan con muchos PEs a través de los cuales distribuyen su memoria) y *adaptativos* (tienen la capacidad de adaptarse al entorno modificando sus pesos y sinapsis de manera de encontrar una solución aceptable al problema). Según estos autores, estos tres conceptos se traducen en un mejor rendimiento y en una mayor velocidad de procesamiento. Por su parte, 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 las muestras puede ser generalizado a las observaciones no vistas, es decir, puede ser empleado para proporcionar una respuesta correcta ante datos no utilizados en el entrenamiento de la red. La literatura sugiere que las redes neuronales poseen varias ventajas potenciales sobre los métodos estadísticos tradicionales, destacándose el que éstas pueden ser aproximadores de funciones universales aún para funciones no lineales (Hornik, Stinchcombe & White, 1989), lo que significa que ellas pueden aproximar automáticamente cualquier

² Las redes neuronales pueden entenderse como modelos multiecuacionales o multi-etapas, en los que el output de unos constituye el input de otros. 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 1995-96).

**Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index**

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, Marquez, O'Connor & Remus, 1994).

Los PEs son un dispositivo simple de cálculo que, a partir de un vector de entrada procedente del exterior o de otras neuronas, proporciona una única respuesta o salida, la que se puede conectar a otros PEs de la red. Los PEs se agrupan formando capas las que, a su vez, conforman las llamadas redes neuronales (Freeman y Skapura, 1993). Los componentes de una red neuronal son: (a) *unidades de entrada*, las cuales reciben información proveniente de otras neuronas o desde el exterior, para luego traspasarla a la capa siguiente sin realizar procesamiento alguno; (b) *unidades de salida*, las cuales corresponden al resultado de la red neuronal; y (c) *unidades ocultas*, que son aquellas en donde se lleva a cabo el procesamiento de los datos. Luego, el problema se centra en determinar los parámetros adecuados de las redes neuronales que contengan la combinación correcta de elementos de procesamiento, tasas de aprendizaje, arquitectura y número de capas con tiempos de entrenamientos aceptables y que posean un buen rendimiento.

B. Aplicaciones de los modelos de redes neuronales

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 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 agentes económicos tales como

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

compañías, para obtener una estimación de la probabilidad de quiebra (por ejemplo, Odom & Sharda, 1990; Wilson & Sharda, 1994; Rahimian, et al., 1993), compañías de seguros (Brockett, Cooper, Golden & Pitaktong, 1994), la capacidad acreedora de clientes bancarios (Marose, 1990), tenedores de tarjetas de crédito (Jagielska & Jaworski, 1996), etc.; segundo, la predicción de series de tiempo (Tang, 1991, et al). Con respecto a esto último, cabe señalar 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 modelos de redes neuronales 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 USA. (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).

Sin embargo, para una clara comprensión y una correcta utilización de los modelos de redes neuronales, se deben tener presentes las limitaciones presentadas por ellos: sus modelos estimados son difíciles de explicar debido a su compleja forma funcional; los modelos de redes neuronales no lineales no poseen propiedades estadísticas clásicas, razón por la cual no es posible realizar pruebas de hipótesis y construir intervalos de confianza; puede ocurrir un sobreajuste a los datos de la muestra o un sobreaprendizaje de la red (el cual se produce cuando el sistema se ajusta demasiado a los datos de entrenamiento, aprendiendo incluso el ruido presente en ellos, por lo que crece el error ante patrones diferentes a los empleados en el

**Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index**

entrenamiento y disminuye la precisión de la proyección), dados los muchos parámetros que necesitan ser estimados para los modelos multivariados (Gorr, 1994); y no existe una guía objetiva para seleccionar la dimensión apropiada de la red (es decir, el número de capas ocultas o neuronas), donde la implementación usualmente se realiza a través de un proceso de prueba y error, aunque se ha sugerido el empleo de métodos sistemáticos tales como el Support Vector Networks Method (Herbrich, Keilbach, Graepel, Bollmann-Sdorra & Obermayer, 2000).

C. La conciencia desde una perspectiva no financiera

Aunque en el concierto científico aún no se ha logrado consenso en definir el concepto de conciencia, cuál es su labor principal y cómo funciona, autores de áreas tan diversas como la neurociencia o la filosofía han realizado esfuerzos considerables para sentar las bases que permitan estudiar este concepto. Por ejemplo, en su trabajo de 1998, Damasio plantea que la conciencia sí puede ser definida. Es más, cree que todos podemos dar una definición relativamente correcta de ella aún en ausencia de conocimiento teórico al respecto. Para reflejar esta aparente simplicidad en entender el concepto de conciencia, Damasio indica que, por ejemplo, si tomamos cualquier diccionario de calidad, éste nos entregaría la siguiente definición de acerca del concepto en cuestión: “conciencia es lo que nos permite tener conocimiento acerca de nuestra existencia, sensaciones, pensamientos y de nuestro entorno”.

Desde la filosofía, Chalmers (1995) ha escrito que para aventurarse en el estudio de la conciencia, los investigadores debieran distinguir entre la parte fácil del problema y la difícil. Lo fácil estaría constituido por algunos de los siguientes problemas: la habilidad de discriminar, categorizar y reaccionar a los estímulos externos, la integración de la información dentro de un sistema cognitivo, la habilidad de poseer un sistema que nos permita acceder a

**Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index**

nuestros propios estados mentales, entre otros. Chalmers (1995) cree que esto sería fácil de estudiar, por cuanto se poseen en la actualidad las herramientas y metodologías para lidiar con estos problemas³.

La arista difícil del problema estaría en estudiar las experiencias relativas o lo subjetivo que es percibido por cada individuo. Por ejemplo, cómo es que unas personas al ser expuestas a un mismo estímulo auditivo, pueden tener experiencias diversas al respecto; cómo que aun siendo la información procesada de la misma en todos los organismos humanos, la respuesta de ellos pueda ser distinta.

Crick & Koch también han investigado fuertemente acerca de la consciencia, abordando el tema desde la neurociencia. Ellos plantean en su trabajo de 1990 que quizá sea mejor evitar dar una definición precisa de consciencia, pues existe peligro de que ello sea prematuro; que la consciencia no requiere necesariamente de la existencia de lenguaje para existir dentro de un organismo; que existen varios tipos de consciencia, tales como las que están relacionadas con la vista, los pensamientos, emociones, el dolor y otras.

Damasio (1998) también hace una diferenciación de variedades de consciencia, aunque no en el mismo sentido que reconocen Crick & Koch (1990). Damasio plantea que existen dos niveles de consciencia: la consciencia nuclear y la consciencia extendida. La consciencia nuclear es aquella que nos permite sentir que los pensamientos que cruzan nuestra mente son propios y privados a la vez, originados desde nuestra perspectiva y que los podemos utilizar según nuestra voluntad. Por otra parte, la consciencia extendida está constituida por una serie de pensamientos interrelacionados entre sí que nos permiten formar un yo autobiográfico, es decir, estos pensamientos describen no sólo el presente del individuo, sino también su pasado

³ Aunque plantea que lo “fácil”, tal vez podría demorar uno o dos siglos de investigación.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

y constituyen la base para establecer su futuro esperado. Según Damasio, estos dos tipos de conciencia debieran trabajar conjuntamente, específicamente, dependiendo la segunda de la primera.

Otro tipo de conciencia, complementario al concepto de “conciencias de” planteado por Crick and Koch (1990) es el de la autoconciencia. La autoconciencia o conciencia de uno mismo sería algo similar a lo que plantea Damasio como conciencia nuclear, un estado general de la mente humana que nos permite reconocer qué cosas le ocurren a mi persona (emociones, pensamientos, sensaciones, etc.) y diferenciarlas de las cosas que ocurren a otros. Este tipo de conciencia, que principalmente ha sido defendida por los filósofos actuales, encuentra en Churchland & Churchland (1990) una crítica, por cuanto se plantea que la autoconciencia no es más que un conjunto de “conciencias de”, denominadas de otra forma, con lo cual, en esencia, se estaría enturbiando el análisis.

Casacuberta (2001) desarrolla una idea que tiende a validar tanto la autoconciencia como la crítica a ella mencionada por Churchland & Churchland (1990). Según él la autoconciencia estaría presente en nosotros aunque no tengamos disponibles ciertas “conciencias de”. Esto se debería al concepto de la propiocepción, es decir, a la capacidad de percibir que estamos situados en un lugar físico particular y localizar cada parte de nuestro organismo en cierto “sistema de referencia propio” sin tener la necesidad de la observación directa. La propiocepción estaría presente, según Casacuberta, aun en el caso en que tengamos nuestro cuerpo sometido a una parálisis.

Los conceptos de autoconciencia y de conciencia nuclear son claves en el desarrollo de este trabajo. Así como Casacuberta (2001) plantea que la autoconciencia permitiría al hombre generar representaciones de sí mismo y simular el futuro e incluirse en él, una

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

característica deseable de una red neuronal conciente en algún grado sería que utilice información acerca de sí misma y pueda evaluar que tipo de comportamiento, en este caso arquitectura y otra de sus configuraciones, es más apropiado para conseguir mejores resultados en relación con el problema que debe resolver.

Importante es mencionar que en este estudio no se pretende agotar el tema de la conciencia en las redes neuronales, sino que la intención es contribuir al debate e incentivar la participación de más actores en las investigaciones relacionadas, por lo menos, en el ámbito financiero.

III. Metodología

A. Datos

En esta investigación se utilizaron 263 precios de cierre semanales para cada una de las acciones que componen el Índice Dow Jones Industrial Average, los cuales corresponden a las cotizaciones registradas entre el 28 de Septiembre de 2001 y 6 de Octubre de 2006 inclusive. Estos datos fueron recopilados de la base de datos del portal finance.yahoo.com. Cada uno de los precios obtenidos fue ajustado para eliminar las distorsiones que provocan los pagos de dividendos y los splits de cada stock. Además se consideran 263 datos de los índices Dow Jones Industrial Average y Nasdaq Composite para el período ya mencionado.

Con estos datos se procede a calcular las variaciones porcentuales semanales o rentabilidades de cada activo quedando una muestra final de variables con 262 observaciones cada una. Estas observaciones se dividen en cuatro conjuntos distintos:

- a. conjunto de entrenamiento, compuesto por los primeros 111 datos, los cuales serán utilizados para del problema a resolver,
- b. conjunto de validación, que lo constituyen las observaciones 112 a la 121 y que permiten a la red monitorear el aprendizaje en el conjunto de entrenamiento,
- c. conjunto de testeo, compuesto por las siguientes 10 observaciones, las cuales no se utilizan en el entrenamiento de la red (son datos desconocidos para ella), pero que permiten evaluar posibles divisiones en las características de los datos, y por último,
- d. conjunto de producción o extramuestral, constituido por las 131 observaciones restantes y que permitirán probar la capacidad predictiva de la red.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

B. Variables

En cada modelo formulado, la variable de salida estará dada por la variación porcentual del precio en el período corriente “t” de la acción que se quiere predecir, mientras que el conjunto de variables de entrada estará constituido por un máximo de seis rezagos de las variaciones porcentuales de la acción (Δ Acción) a predecir y un máximo de seis rezagos de las variaciones porcentuales de los índices Dow Jones Average Industrial (Δ DJI) y Standard & Poors 500 (Δ GSPC). Luego, cada modelo tendría como máximo la siguiente estructura:

$$\Delta Accion_t = g \left(\begin{array}{l} \Delta Accion_{t-1}, \Delta Accion_{t-2}, \Delta Accion_{t-3}, \Delta Accion_{t-4}, \Delta Accion_{t-5}, \Delta Accion_{t-6}, \\ \Delta DJI_{t-1}, \Delta DJI_{t-2}, \Delta DJI_{t-3}, \Delta DJI_{t-4}, \Delta DJI_{t-5}, \Delta DJI_{t-6}, \\ \Delta GSPC_{t-1}, \Delta GSPC_{t-2}, \Delta GSPC_{t-3}, \Delta GSPC_{t-4}, \Delta GSPC_{t-5}, \Delta GSPC_{t-6} \end{array} \right) \quad (1)$$

Se habla de un número máximo de rezagos porque se entrega libertad a la red neuronal de poder seleccionar los inputs óptimos que utilizará en su entrenamiento. En ese sentido, se emplea un enfoque similar al planteado por Parisi, Parisi y Cornejo (2004), donde se muestra que la técnica de algoritmos genéticos permite optimizar la estructura de los modelos multivariados dinámicos en busca de un mejor resultado en términos predictivos.

C. Software

En este estudio se emplearon tres programas computacionales para procesar los datos:

- a. Matlab versión 7.0 y su herramienta Neural Network Toolbox versión 4.0
- b. Microsoft Excel 2003
- c. Microsoft Visual Basic versión 6.3

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

D. Aplicación del concepto de conciencia en las redes neuronales

Como se mencionó en la revisión bibliográfica, una característica importante de la conciencia humana es la capacidad para aprender de nuestro comportamiento y poder adaptarnos a las circunstancias del ambiente en el cual estamos insertos. Aún cuando en la actualidad las redes neuronales pueden de cierta forma aprender del problema y los datos con los cuales se está trabajando, no se han encontrado, por lo menos en la literatura financiera, aplicaciones de redes neuronales que tengan la capacidad de aprender de sí mismas y de las condiciones del ambiente de trabajo como una forma de adaptarse para mejorar su rendimiento. En concordancia con esto, en esta investigación se da el primer paso para comenzar con el estudio de la conciencia aplicada a las redes neuronales. En particular, se quiere mostrar que las redes neuronales podrían optimizar su arquitectura (adaptarse) de modo que su capacidad de aprendizaje del problema a resolver mejore.

Debido a la complejidad de generar un algoritmo específico para que la red adquiriera la característica de pensarse a sí misma y adaptar su arquitectura convenientemente, en esta primera etapa de investigación se implementará el concepto de conciencia en las redes neuronales a través de un algoritmo de aprendizaje que estará representado por un algoritmo genético, en cual será detallado en la siguiente subsección. En la práctica, este algoritmo seleccionará la arquitectura óptima de la red para cada acción, alterando en su proceso de funcionamiento las conexiones que existen entre la capa de entrada, oculta y salida, así como las conexiones que existen entre los distintos slabs de la capa oculta.

En este trabajo no se pretende mostrar la habilidad de los algoritmos genéticos para resolver problemas y, por lo mismo, no se realizará un análisis exhaustivo de su

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

funcionamiento. Sí podemos mencionar que la metodología se corre hasta un número máximo de 15 generaciones por acción, donde en cada generación se prueban 100 arquitecturas posibles.

E. Algoritmos genéticos y la implementación del concepto de conciencia

Los algoritmos genéticos, 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 a cada una de las posibles soluciones al problema. Por ello, es necesario establecer una codificación para todo el rango de soluciones, antes de comenzar a trabajar con el algoritmo. Al respecto, Davis (1994) señala que la codificación más utilizada es la representación de las soluciones por medio de cadenas binarias (conjuntos de ceros y unos).

Para la implementación de la característica de conciencia en las redes neuronales, los algoritmos genéticos son utilizados para encontrar tanto la arquitectura óptima de la red como el set óptimo de variables de entrada. El procedimiento de búsqueda considera los siguientes pasos:

- a. Se codifican aleatoriamente 100 arquitecturas, utilizando un código binario para establecer las conexiones entre los distintos *slabs* de la red. Al mismo

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

tiempo, se codifican con códigos binarios al azar, 100 conjuntos de variables de entrada. Así, tenemos 100 redes neuronales creadas, donde cada red tiene asignado un único conjunto de variables de entrada.

- b. Cada una de estas redes neuronales son entrenadas con las características descritas en las secciones siguientes, se obtienen sus proyecciones y los estadísticos de desempeño que se explican más adelante.
- c. Una vez entrenadas las cien redes neuronales aleatorias, se ordenan descendientemente por el estadístico PPS extramuestral que se explica más adelante. Si este estadístico no es suficiente para ordenar los modelos, se procede a ordenarlos tanto por PPS extramuestral como por la rentabilidad que se alcanza en el activo comprando y vendiendo según las predicciones del modelo.
- d. El mejor modelo es denominado el mejor modelo de la generación en curso, y se conservan sus resultados.
- e. Se seleccionan los 10 mejores modelos en términos de PPS extramuestral.
- f. Los 10 mejores modelos se reproducen con un cross-over de dos puntos centrales. Un punto corta el código de la arquitectura, mientras que el segundo corta el código de variables. De esta reproducción nacen 90 hijos.
- g. Se crea una nueva generación compuesta de los 90 hijos y los 10 padres, es decir, 100 individuos.
- h. Se obtienen los códigos genéticos de la nueva generación y se muta al 8% del total de genes de la generación. Con esto obtenemos una nueva generación mutada.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

- i. Una vez que la nueva generación ha pasado por el proceso de mutación, se calibran otra vez los modelos, i.e., se entrenan las nuevas redes neuronales generadas.
- j. Este proceso se repite 15 veces para cada uno de los 30 activos que componen el índice Dow Jones. Así cada activo estudiado posee 15 mejores modelos, donde cada uno de esos modelos pertenece a una generación distinta.

F. Arquitectura de las redes neuronales

Como se mencionó en el punto anterior cada red neuronal debe buscar su arquitectura óptima utilizando un algoritmo genético como algoritmo de aprendizaje. Sin embargo, es necesario entregar a la red un espacio de soluciones factibles para que el aprendizaje finalice en algún momento. En consecuencia, la arquitectura máxima en términos de slabs y conexiones y neuronas se detalla a continuación:

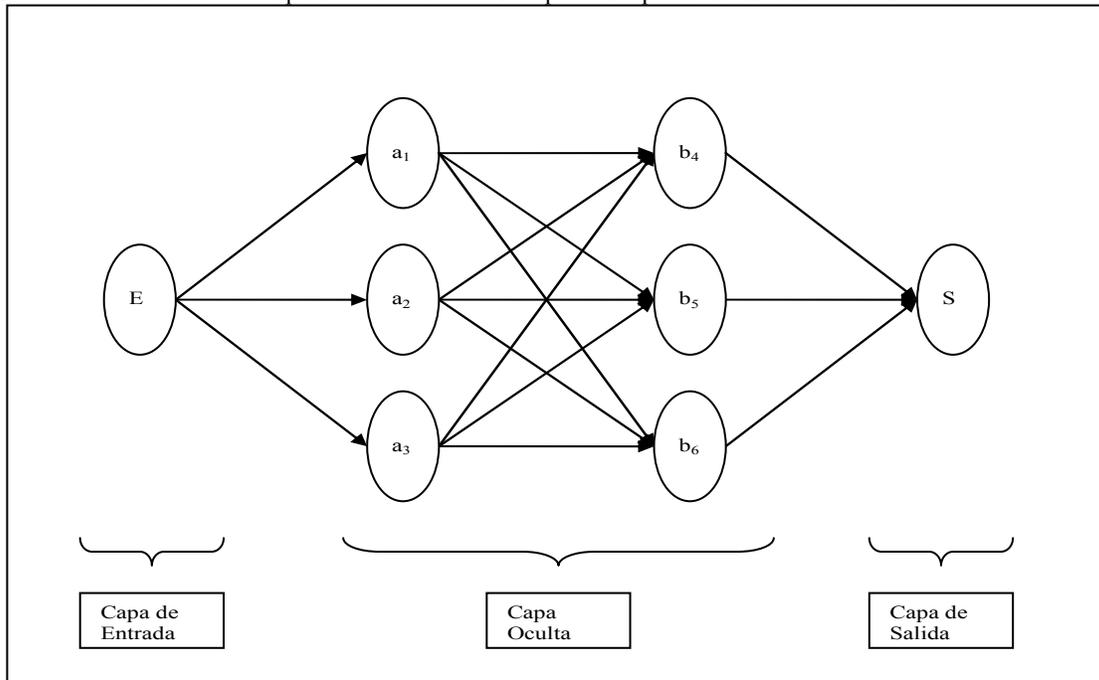
- a. Número slabs en la capa de entrada: 1
- b. Número de capas ocultas: 2, a saber, la A y la B.
- c. Número de slabs en cada capa oculta: 3
- d. Número de slabs en la capa de salida: 1
- e. Máximo de conexiones entre la capa de entrada y capa oculta: 6, 1 conexión por cada slab de la capa oculta.
- f. Máximo de conexiones entre las capas ocultas: 9. Los slabs en la capa oculta A no se conectan entre sí, así como tampoco lo hacen los de la capa oculta B.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

- g. Máximo de conexiones entre la(s) capa(s) oculta(s) y la capa de salida: 6, es decir, pueden existir conexiones desde cada slab en las capas A y B y el slab de la capa de salida.
- h. Las conexiones sólo se realizan hacia delante, es decir, desde la capa de entrada hacia la capa oculta y desde esta hacia la capa de salida, nunca a la inversa. Tampoco se permite que existan conexiones donde un output de la capa oculta B sea input de la A.
- i. Número de neuronas en cada slab de la capa oculta: determinadas aleatoriamente para cada modelo, con un mínimo de 5 y un máximo de 15 neuronas.

Figura 1: Posible solución en la Arquitectura Óptima de la Red Neuronal.

Se muestra un ejemplo de la arquitectura de podría tomar una red neuronal en su proceso de optimización a través de la conciencia. Cualquiera de los slabs de la capa oculta podría no incluirse si es necesario.



Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

G. Funciones de Transferencia y Otras Características

Cada uno de los slabs en cada capa oculta tiene asociado una única función de transferencia. Utilizando la nomenclatura de la figura 1, las funciones de transferencia se distribuyen como sigue:

- a. A1: Tangente Sigmodeana (tansig)
- b. A2: Lineal (purelin)
- c. A3: Complemento Gaussiana (comgaussiana)
- d. B1: Radial Basis (radbas)
- e. B2: Tangente Sigmodeana (tansig)
- f. B3: Complemento Gaussiana (comgaussiana)
- g. S: Lineal (purelin)

Otras características de las redes que se entrenaron son:

- a. Algoritmo de Entrenamiento: Resilient Backpropagation (Trainrp). Se utiliza en este estudio un algoritmo de retropropagación porque en estudios anteriores ha quedado demostrado que las redes neuronales supervisadas tienen un buen desempeño con series de tiempo.
- b. Función de desempeño para evaluar entrenamiento: Sum Squared Error (sse)
- c. Función de Adaptación: Incremental Training (Trains)
- d. Función de Inicialización de Parámetros: Layer-by-layer network initialization function. (Initlay).

H. Evaluación de la capacidad predictiva de las redes neuronales y análisis comparativo

Cada uno de los modelos de proyección generados fue estimado y validado a partir de los datos del conjunto de entrenamiento. Este proceso fue seguido por una evaluación empírica sobre la base de los datos del conjunto extramuestral⁴. En esta etapa, el desempeño relativo de los modelos fue medido por el número de predicciones correctas (hits) del signo del retorno del índice. Así, al igual que Kanas (2001), la proyección extramuestral fue testada en función de su precisión direccional (directional accuracy, DA), a través de la prueba de signo. Para examinar la precisión direccional se empleó el test de Pesaran & Timmermann (1992), el cual compara el signo de la proyección, \hat{y}_{n+i} , con el del valor observado, y_{n+i} , para cada i -ésima observación del conjunto extramuestral ($i=1,2, \dots, 131$), donde el signo indica la dirección en que se moverá el mercado accionario: al alza, si es positivo, o a la baja, si es negativo. Si los signos coinciden, aumenta la efectividad de la red, y en caso de no existir coincidencia, aumenta el error de predicción de la red.

El ratio de éxito (SR) se define como:

$$SR = m^{-1} \sum_{i=1}^m I_i [y_{n+i}, \hat{y}_{n+i} > 0] \quad (2)$$

donde $I_i[\cdot]$ es una función indicador que toma el valor de 1 cuando su argumento es cierto y 0 en otro caso. Además:

$$P = m^{-1} \sum_{i=1}^m I_i [y_{n+i} > 0] \quad (3)$$

⁴ Cabe mencionar que Sharda (1994) señala que los resultados basados en tal comparación están sujetos a una muestra sesgada, lo que atenta contra su significancia estadística.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

y

$$\hat{P} = m^{-1} \sum_{i=1}^m I_i [\hat{y}_{n+i} > 0] \quad (4)$$

El ratio de éxito en el caso de independencia de \hat{y}_{n+i} y y_{n+i} , SRI, está dada por:

$$SRI = P \cdot \hat{P} + (1 - P)(1 - \hat{P}) \quad (5)$$

cuya varianza es:

$$VAR[SRI] = m^{-2} \left[m(2 \cdot \hat{P} - 1)^2 P(1 - P) + m(2 \cdot P - 1)^2 \hat{P}(1 - \hat{P}) + 4 \cdot P \cdot \hat{P}(1 - P)(1 - \hat{P}) \right] \quad (6)$$

Por su parte, la varianza de SR se define como:

$$VAR[SR] = m^{-1} \cdot SRI(1 - SRI) \quad (7)$$

Finalmente, el test DA de Pesaran & Timmermann (1992) está dado por:

$$DA = (VAR[SR] - VAR[SRI])^{-1/2} (SR - SRI) \quad (8)$$

Además, los resultados de los modelos de redes neuronales analizados serán comparados con los de un modelo ingenuo o AR(1), el cual se presenta en la ecuación (9).

$$\Delta Accion_t = \alpha_1 \cdot \Delta Accion_{t-1} + \varepsilon_t \quad (9)$$

donde ε_t representa el término de error, y α_1 es el coeficiente que acompaña a la variable explicativa.

IV. Simulación y Análisis de los Resultados

En la Tabla 1 se muestran los mejores modelos encontrados para cada uno de los activos utilizados en esta investigación. La segunda columna indica la generación del algoritmo genético en que fue encontrada la mejor red neuronal con rasgos de conciencia, donde “mejor” hace referencia al modelo de red neuronal, con capacidad de predicción de signo estadísticamente significativa, que obtiene la mayor rentabilidad en el conjunto extramuestral. La tercera columna muestra el porcentaje de predicción de signo para el set de datos de producción o conjunto extramuestral de la mejor red neuronal encontrada, mientras que la cuarta columna muestra el mismo estadígrafo para el conjunto de intramuestral, es decir, la adición de los conjuntos de entrenamiento, validación y testeo. Las columnas quinta, sexta y séptima muestran las rentabilidades que se devengan en el período extramuestral siguiendo las predicciones del modelo de red neuronal, siguiendo una estrategia de *buy and hold* y siguiendo las predicciones de un modelo ingenuo, respectivamente. Por último, la columna octava muestra el valor del test de acierto direccional de Pesaran y Timmermann.

Se encuentra que, de la totalidad de los activos que se modelaron, en un 80% de los casos, las redes neuronales con rasgos de conciencia encontraron al menos una red óptima en el proceso de búsqueda cuyos resultados extramuestrales fueran tanto económica como estadísticamente significativos. La significancia desde la perspectiva económica evalúa los resultados en términos de la rentabilidad entre seguir las predicciones de la técnica encontrada con las redes neuronales con rasgos de conciencia y seguir una estrategia pasiva o una activa pero ingenua, mientras la perspectiva estadística dice relación con la significancia al nivel del

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

10% -por lo menos- de la capacidad de predicción de signo, medida ésta a través del test de Pesaran y Timmermann.

Tabla 1: Resultados de los mejores modelos encontrados a través de redes neuronales con características de conciencia.

En esta tabla se puede apreciar que para la totalidad de las acciones estudiadas se ha encontrado al menos un modelo con capacidad estadísticamente significativa en la predicción de signo del cambio de precio semanal, debido a que los tests calculados de Pesaran y Timmermann permiten rechazar la hipótesis nula de que no existe capacidad de predicción de signo.

Acción	Generación	PPS.Extra (%)	PPS.Intra (%)	Rent.Cart (%)	Rent.B&H (%)	Rent.Naïve (%)	P&T
AA	13	58,78	54,20	9,13	-13,86	-25,00	2,15**
AG	4	61,07	61,83	35,79	-10,59	27,84	2,65***
AXP	9	60,31	50,38	37,69	26,94	13,32	2,20**
BA	14	67,18	54,20	63,75	110,72	42,54	3,42***
C	15	67,18	61,83	21,05	8,99	18,87	3,81***
CAT	11	61,83	55,73	69,13	73,58	-7,63	1,93*
DD	1	60,31	51,91	43,90	12,52	9,53	2,36***
DIS	14	63,36	53,44	48,16	21,76	-9,37	3,03***
GE	11	61,07	62,60	24,60	22,93	11,58	2,52***
GM	1	61,07	54,20	65,58	-24,16	-14,91	2,58***
HD	6	60,31	70,99	21,06	5,57	-5,26	2,39***
HON	2	61,83	60,31	35,43	28,99	7,74	2,76***
HPQ	1	61,83	58,78	88,66	70,37	-5,45	3,04***
IBM	9	61,07	51,91	21,31	-8,41	14,10	2,22**
INTC	3	59,54	50,38	5,67	-22,03	-30,62	2,20**
JNJ	14	64,12	53,44	47,59	34,76	7,73	3,01***
JPM	10	62,60	54,20	45,71	24,30	14,26	2,75***
KO	12	64,89	61,83	13,24	-6,85	-6,19	3,39***
MCD	14	58,78	54,20	38,68	45,43	16,80	2,12**
MMM	4	63,36	54,96	9,93	-2,84	-19,68	3,01***
MO	12	61,07	62,60	64,17	59,60	33,27	2,16**
MRK	13	61,83	51,15	56,09	4,86	36,29	2,97***
MSFT	12	58,78	70,23	17,82	25,15	-5,44	2,01**
PFE	9	62,60	61,83	13,23	-15,57	6,23	2,74***
PG	15	63,36	54,20	31,34	24,66	3,44	2,73***
T	11	63,36	58,02	35,75	47,33	15,53	3,07***
UTX	8	60,31	48,09	47,75	51,76	3,94	2,17**
VZ	10	60,31	50,38	58,66	10,44	-6,63	2,36***
WMT	14	57,25	89,31	-1,61	-12,13	-4,99	1,68*
XOM	7	61,07	54,96	86,02	67,66	24,84	1,74*

(***) Significativo al nivel de 1%
(**) Significativo al nivel de 5%
(*) Significativo al nivel de 10%

**Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index**

Entre los resultados más importantes está el hecho de que en más del 60% de los activos que se utilizaron para este trabajo se encontraron modelos que mostraban una capacidad de acierto de signo significativa al nivel del 1% y que a su vez obtuvieron una rentabilidad superior tanto a la estrategia pasiva como a la estrategia ingenua, lo cual es poco usual cuando se habla de modelos predictivos para series de precios accionarios del Dow Jones. De estos modelos destaca la red neuronal encontrada para General Motors donde ya en la primera generación se encontró un modelo significativo al 1% en términos estadísticos y donde la rentabilidad alcanzada por la estrategia de seguir las predicciones del modelo llegó al 65,58%, superior en más de 89 puntos porcentuales a la conseguida por la estrategia comprar y mantener.

Sólo se producen 6 casos dónde la mejor red neuronal encontrada no puede superar la rentabilidad de la estrategia pasiva aún teniendo capacidad de predicción de signo significativa. Es el caso de las acciones de Boeing, Caterpillar, McDonalds, Microsoft, AT&T y de United Technologies Corp. Esto podría deberse a que la generación inicial de redes para estos activos no fue lo suficientemente general como para permitir que los rasgos de conciencia encuentren una solución óptima global en términos económicos. Dicho de otro modo, tal vez si alteramos la población inicial de modelos podríamos encontrar una solución satisfactoria en el sentido comentado. Otra posible solución podría estar en permitir un número mayor de generaciones para cada activo. Sin embargo, en opinión del autor de este trabajo, los resultados así presentados muestran suficientemente bien las virtudes de los modelos de redes neuronales con características de conciencia.

En el anexo de este documento se encuentran los resultados de los modelos más destacados de cada uno de los activos estudiados.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

Tabla 2: Resultados del procedimiento *Block Bootstrap*.

En la primera columna de esta tabla se presenta el nemotécnico del activo en estudio. En la columna PPS Promedio se observa el porcentaje de predicción de signo promedio en las muestras *bootstrap* para cada activo. La columna Rent.Cart muestra la rentabilidad promedio en las muestras *bootstrap* de la estrategia de seguir las predicciones del modelo. Rent.B&H y Rent.Naïve son las rentabilidades promedios en las muestras *bootstrap* de la estrategia pasiva y de la estrategia ingenua, respectivamente. $P\text{-value}_B$ representa el nivel mínimo de significancia al cual se puede rechazar la hipótesis nula de que las medias de las rentabilidades entre la estrategia propuesta por la red neuronal y la estrategia pasiva son iguales, en favor de la hipótesis alternativa de que son distintas, mientras que $P\text{-value}_N$ representa el nivel mínimo de significancia al cual se puede rechazar la hipótesis nula de que las medias de las rentabilidades entre la estrategia propuesta por la red neuronal y la estrategia ingenua son iguales, en favor de la hipótesis alternativa de que son distintas. La columna $Rc>Rb$ muestra la fracción de veces en la estrategia propuesta por la red neuronal fue superior en rentabilidad en las muestras *bootstrap* a la estrategia *buy and hold*. En la columna $Rc>Ri$ se muestra el mismo estadístico pero comparando la estrategia activa propuesta por la red neuronal con la estrategia ingenua. Por último, $Rc>R$ muestra la fracción de veces en que la estrategia de seguir las predicciones de la red neuronal fue superior tanto a la estrategia pasiva como a la ingenua.

Acción	PPS Promedio ¹ (%)	Rent. Cart (%)	Rent. B&H (%)	Rent. Naïve (%)	$P\text{-value}_B$ ²	$P\text{-value}_N$ ³	$Rc>Rb$ ⁴	$Rc>Ri$ ⁵	$Rc>R$ ⁶
AA	48,21	-5,97	0,22	-29,51	0,07	0,00	0,32	0,74	0,32
AIG	49,01	-0,27	0,14	-21,72	0,90	0,00	0,43	0,66	0,37
AXP	52,99	7,47	-0,72	-5,56	0,00	0,00	0,71	0,71	0,61
BA	54,40	22,02	2,76	19,89	0,00	0,83	0,56	0,54	0,42
C	54,04	4,51	0,36	3,74	0,02	0,79	0,56	0,53	0,37
CAT	54,33	26,70	3,23	67,51	0,01	0,01	0,58	0,37	0,29
DD	49,86	3,58	-0,42	-10,51	0,11	0,00	0,57	0,73	0,48
DIS	51,27	4,56	-0,71	25,11	0,10	0,00	0,55	0,29	0,25
GE	51,72	3,84	-0,27	-1,84	0,01	0,01	0,58	0,65	0,47
GM	48,15	22,80	8,13	-32,63	0,07	0,00	0,51	0,77	0,48
HD	45,63	10,17	-0,74	9,44	0,00	0,85	0,67	0,51	0,43
HON	51,64	9,67	-0,31	-7,90	0,00	0,00	0,63	0,73	0,54
HPQ	49,55	22,75	3,14	85,22	0,01	0,00	0,55	0,39	0,28
IBM	47,94	3,99	-0,28	-8,41	0,05	0,00	0,58	0,67	0,49
INTC	48,06	14,42	1,86	-6,85	0,01	0,00	0,62	0,69	0,51
JNJ	53,52	4,80	0,40	-3,35	0,05	0,01	0,57	0,59	0,42
JPM	53,86	11,41	0,18	-5,83	0,00	0,00	0,66	0,68	0,5
KO	51,33	2,98	1,00	-15,90	0,32	0,00	0,61	0,83	0,57
MCD	48,13	5,86	-1,21	19,53	0,03	0,01	0,54	0,41	0,33
MMM	47,66	4,53	0,79	-4,61	0,06	0,00	0,56	0,74	0,5
MO	54,48	16,20	1,89	23,19	0,01	0,48	0,56	0,55	0,43
MRK	51,79	7,21	4,43	-6,71	0,62	0,04	0,42	0,62	0,34
MSFT	48,12	3,86	-1,90	-19,20	0,00	0,00	0,62	0,85	0,59
PFE	46,59	6,40	3,00	-15,51	0,33	0,00	0,5	0,69	0,45
PG	53,05	1,00	-0,34	-9,94	0,37	0,00	0,5	0,74	0,43
T	51,93	10,28	-0,08	-12,70	0,00	0,00	0,64	0,73	0,56
UTX	53,23	10,70	0,61	-8,34	0,01	0,00	0,54	0,72	0,46
VZ	50,21	5,79	0,13	-23,65	0,02	0,00	0,58	0,82	0,55
WMT	49,62	4,61	1,22	-16,65	0,12	0,00	0,54	0,79	0,5
XOM	53,78	10,48	-0,15	2,59	0,01	0,16	0,6	0,55	0,39

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

Para testear la robustez de los resultados encontrados y evitar el problema de *data snooping* se generaron 100 conjuntos extramuestrales para cada acción mediante el proceso denominado *block bootstrap*. Dado que en este caso no estamos considerando metodologías *rolling* o recursivas, las redes no se volvieron a entrenar para proyectar los nuevos conjuntos extramuestrales, sino que se procedió a simular los distintos conjuntos extramuestrales generados con *bootstrap* con los parámetros de las mejores redes halladas. Los resultados que se obtienen del proceso de *bootstrap* indican que la calidad de los resultados en términos de predicción de signo cae de manera importante, ya que en promedio sólo un 5% de los test de *directional accuracy* calculados para cada acción permiten rechazar la hipótesis nula de que no existe capacidad de predicción de signo. Esto muestra que los resultados en términos de capacidad de predicción de signo presentan problemas de robustez.

No obstante lo anterior, se presenta evidencia en la Tabla 2 de que aún sin capacidad de predicción de signo significativa en las muestras *bootstrap*, los modelos de redes neuronales con rasgos de conciencia permiten alcanzar mejores resultados en comparación con otras estrategias. Esto se refleja en el hecho de que en 19 de las 30 acciones estudiadas la estrategia propuesta por la red neuronal acarrea mayores beneficios que la estrategia comprar y mantener, mientras que el número de casos positivos aumenta a 21 si comparamos la rentabilidad de la red neuronal con la rentabilidad del modelo ingenuo. Además, en el 36% de los activos los resultados de la red neuronal son significativamente mayores en términos estadísticos que los conseguidos por la estrategia pasiva y que por la estrategia ingenua. Esta significancia estadística se determina al comparar las distribuciones de las rentabilidades por medio de una prueba t de Student de dos muestras suponiendo varianzas poblacionales distintas.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

Los problemas de robustez en términos de capacidad de predicción de signo podrían ser solucionados al utilizar un modelos con muestras *rolling* o modelos recursivos, lo cuales no se emplearon en este trabajo por la alta capacidad de calculo computacional requerida para estimar dichos modelos. En estudios futuros esta dificultad podría ser sanjada al utilizar computadores con mayor capacidad de procesamiento.

V. Conclusiones

La primera aproximación del concepto de conciencia aplicado a las redes neuronales artificiales utilizadas en la predicción de signo de variación de precios de activos financieros ha sido auspiciosa. Se encontró que las redes neuronales con rasgos de conciencia tienen capacidad estadísticamente significativa para predecir la rentabilidad semanal de las acciones que componen el índice Dow Jones Average Industrial y que esta capacidad de predicción se traduce efectivamente en beneficios económicos más altos que los que se conseguirían siguiendo una estrategia de comprar y mantener o comprar según las predicciones que entrega un modelo autorregresivo de primer orden o modelo ingenuo.

El hecho de que la técnica haya encontrado resultados positivos en la totalidad de los activos que componen principal índice accionario mundial valida el aporte que hace el estudio en el modelamiento de series de retornos de activos financieros.

Quedará para una futura investigación solucionar el problema de la robustez en la capacidad predictiva, aunque tal vez la mejor prueba de la efectividad de la técnica acá planteada provenga del ámbito empírico-práctico, al aplicar estos modelos de redes neuronales con rasgos de conciencia en la administración de portfolios de inversión.

También es intención del autor de esta tesis proponer investigaciones futuras, igualmente generales en relación a los activos a modelar, que incorporen el entrenamiento y predicción dinámicos por medio de metodologías *rolling* o recursivas, ya que este tipo de modelos han mostrado desempeños superiores en comparación con modelos estáticos.

**Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index**

Referencias Bibliográficas

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, pp. 371-402.

Brockett, P. W., Cooper W. W., Golden L. L. & Pitaktong U. (1994). A neural network method for obtaining an early warning of insurer insolvency. *The Journal of Risk and Insurance* 6, p.p. 402-424.

Casacuberta, D. (2001). La mente humana. *Barcelona, Editorial Océano*.

Chalmers, D. J. (1995). Facing up to the problem of consciousness. *Journal of Consciousness Studies* 2:200-19. Reprinted in Shear 1997.

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

Churchland, P. M. and Churchland, P. S. (1990). Intertheoretic reduction: A neuroscientist's field guide. *Seminars in the Neurosciences* 2, 249-256.

Crick, F.C. & Koch, C. (1990). Towards a neurobiological theory of consciousness. *Sem. Neuroci.* 2, 263-275.

Damasio, A. R. (1998). Investigating the biology of consciousness. *Philosophical Transactions of the Royal Society of London - Series B: Biological Sciences*, 353 (1377), 1879-1882.

Davis, Lawrence. (1994). Genetic Algorithms and Financial Applications, in: *Deboeck (ed., 1994)*, pp. 133-147.

**Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index**

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

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

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

Ferson, W. & Harvey, C. (1991). The variation of economic risk premiums. *Journal of Political Economy* 99, p.p. 385-415.

Ferson, W., and Schadt, Rudi. (1996). Measuring fund strategy and performance in changing economic conditions. *Journal of Finance* 51:425–62.

Freeman, J. & Skapura, D. (1993). Redes neuronales: Algoritmos, aplicaciones y técnicas de programación. *Primera Edición. Copublicación de Addison-Wesley Iberoamericana, S.A. y Ediciones Díaz de Santos, S.A. Wilmington, Delaware, USA.* 431 pp.

Gorr Wilpen L. (1994). Research prospective on neural network forecasting. *International Journal of Forecasting* (10)1, pp. 1-4.

Hawley, D., Johnson, J., & Raina, D. (1990). Artificial neural systems: A new tool for financial decision-making. *Financial Analysts Journal* 23, p.p. 63-72.

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.

**Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index**

- 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, pp. 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, p.p. 267-280.
- Hornik, K., Stinchcombe M. & White H. (1989).** Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), p.p. 359-366.
- Jagielska, I. & Jaworski, J. (1996).** Neural network for predicting the performance of credit card accounts. *Computational Economics* 9, p.p. 77-82.
- Jegadeesh, Narasimhan (1990).** Evidence of predictable behavior of security returns. *The Journal of Finance*, Vol. 45(3), p.p. 881-898 (July).
- Kanas, Angelos (2001).** "Neural networks linear forecasts for stocks returns". *International Journal of Finance and Economics*, 6, p.p. 245-254.
- 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, pp.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, p.p. 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, p.p. 385-395.
- Marose, R. A. (1990).** A financial neural network application. *AI Expert*, May, p.p. 50-53.
- Martín del Brío, B. & Sanz, A. (1997).** Redes neuronales y sistemas borrosos: Introducción, teórica y práctica. Primera Edición. *Ra-ma*. 387 pp.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

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, p.p. 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, p.p. 163-168.

Parisi, A., Parisi, F. & Guerrero, J. L. (2003). Modelos Predictivos de Redes Neuronales en Índices Bursátiles, *El Trimestre Económico*, México. (Forthcoming).

Pesaran, M.H. & Timmermann A. (1992). A simple nonparametric test of predictive performance. *Journal of Business and Economic Statistics* 10, pp. 461-465.

Poterba, J. M. & Summers L. H. (1988). Mean reversion in stock prices: Evidence and implications. *Journal of Financial Economics* 22, 27-59.

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, pp. 159-171.

Refenes, A. P. (1995). Neural networks in the capital markets, *Wiley, New York*.

Tang, Z., de Almedia C. & Fishwick P. (1991). Time-series forecasting using neural networks vs. Box-Jenkins methodology. *Simulation*, 57(5), p.p. 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, pp. 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, pp. 315-328.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

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, p.p. 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, p.p. 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, pp. 66-79.

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

Anexo

Tabla 3: Resultados de los mejores modelos encontrados a través de redes neuronales con características de conciencia.

Acción	Generación	PPS.Extra (%)	PPS.Intra (%)	Rent.Cart (%)	Rent.B&H (%)	Rent.Naïve (%)	P&T
AA	5	57,25	55,73	3,93	-13,86	-25	1,67*
	6	58,78	51,91	-11,55			2,07**
	11	57,25	61,83	-6,12			1,69*
	13	58,78	54,2	9,13			2,15**
	15	58,02	62,6	-13,55			1,86*
AG	4	61,07	61,83	35,79	-10,59	27,84	2,65***
AXP	2	58,78	54,2	36,19	26,94	13,32	1,89*
	3	58,78	58,78	37,72			1,74*
	6	58,78	55,73	46,16			1,7*
	9	60,31	50,38	37,69			2,2**
BA	14	67,18	54,2	63,75	110,72	42,54	3,42***
C	7	61,07	54,2	18,94	8,99	18,87	2,41***
	15	67,18	61,83	21,05			3,81***
CAT	11	61,83	55,73	69,13	73,58	-7,63	1,93*
DD	1	60,31	51,91	43,9	12,52	9,53	2,36***
	13	56,49	78,63	30,55			1,71*
DIS	1	61,83	55,73	24,7	21,76	-9,37	2,61***
	2	59,54	58,02	26,19			2,14**
	12	58,02	71,76	26,87			1,67*
	14	63,36	53,44	48,16			3,03***
GE	11	61,07	62,6	24,6	22,93	11,58	2,52***
	15	60,31	57,25	25,64			2,34***
GM	1	61,07	54,2	65,58	-24,16	-14,91	2,58***
	2	58,78	61,83	-2,1			2,03**
	6	62,6	64,12	-9,89			3,08***
	12	58,02	66,41	11,48			2,05**
HD	5	59,54	39,69	31,92	5,57	-5,26	2,3**
	6	60,31	70,99	21,06			2,39***
	8	58,78	67,18	6,76			2,04**
	9	59,54	47,33	34,81			1,85*
HON	1	61,07	54,2	42,23	28,99	7,74	2,29**
	2	61,83	60,31	35,43			2,76***
	3	59,54	50,38	44,95			1,9*

(***) Significativo al nivel de 1%

(**) Significativo al nivel de 5%

(*) Significativo al nivel de 10%

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

Tabla 3 (Continuación): Resultados de los mejores modelos encontrados a través de redes neuronales con características de conciencia.

Acción	Generación	PPS.Extra (%)	PPS.Intra (%)	Rent.Cart (%)	Rent.B&H (%)	Rent.Naïve (%)	P&T
HPQ	1	61,83	58,78	88,66	70,37	-5,45	3,04***
IBM	9	61,07	51,91	21,31	-8,41	14,1	2,22**
INTC	1	59,54	51,15	3,67	-22,03	-30,62	2,18**
	2	59,54	56,49	-10,78			2,18**
	3	59,54	50,38	5,67			2,2**
	4	61,07	52,67	-21,4			2,6***
	5	60,31	65,65	-18,89			2,44***
	6	62,6	69,47	-11,02			2,86***
	9	61,83	76,34	-11,15			2,69***
	10	62,6	62,6	-3,98			2,89***
JNJ	5	62,6	48,09	37,02	34,76	7,73	2,29**
	7	64,12	46,56	38,26			2,78***
	9	63,36	49,62	41,37			2,58***
	10	63,36	48,09	44,15			2,53***
	12	63,36	50,38	43,41			2,53***
	14	64,12	53,44	47,59			3,01***
	15	64,12	46,56	39,67			2,71***
JPM	4	58,78	48,85	28,37	24,3	14,26	2,45***
	10	62,6	54,2	45,71			2,75***
	11	60,31	69,47	42,35			2,19**
KO	1	58,02	65,65	-1,25	-6,85	-6,19	1,81*
	2	60,31	56,49	-2,59			2,33**
	3	59,54	48,09	5,47			2,17**
	4	58,78	49,62	-1,31			1,98**
	6	62,6	60,31	-0,51			2,86***
	7	61,83	62,6	1,76			2,69***
	9	64,89	68,7	-5,69			3,48***
	10	59,54	65,65	-4,26			2,21**
	12	64,89	61,83	13,24			3,39***
	13	63,36	65,65	-0,41			3,08***
	14	61,07	53,44	-5,11			2,51***
	15	58,78	63,36	-4,6			1,99**
MCD	14	58,78	54,2	38,68	45,43	16,8	2,12**

(***) Significativo al nivel de 1%
(**) Significativo al nivel de 5%
(*) Significativo al nivel de 10%

Redes Neuronales con Rasgos de Conciencia:
Aplicación en la predicción de signo de cambios de precios en los componentes del
Dow Jones Industrial Average Index

Tabla 3 (Continuación): Resultados de los mejores modelos encontrados a través de redes neuronales con características de conciencia.

Acción	Generación	PPS.Extra (%)	PPS.Intra (%)	Rent.Cart (%)	Rent.B&H (%)	Rent.Naïve (%)	P&T
MMM	1	58,02	56,49	28,59	-2,84	-19,68	1,88*
	3	61,83	54,2	4,66			2,75***
	4	63,36	54,96	9,93			3,01***
	5	57,25	64,89	-2,49			1,79*
	9	58,78	51,91	2,4			2,21**
	10	60,31	53,44	3,17			2,61***
MO	12	61,07	62,6	64,17	59,6	33,27	2,16**
MRK	4	59,54	55,73	65,27	4,86	36,29	2,19**
	5	60,31	54,20	39,85			2,47***
	6	61,83	48,85	40,54			3,02***
	9	61,83	58,78	40,49			2,68***
	11	61,83	61,07	46,86			2,89***
	12	61,83	53,44	42,60			2,97***
	13	61,83	51,15	56,09			2,97***
MSFT	12	58,78	70,23	17,82	25,15	-5,44	2,01**
PFE	9	62,60	61,83	13,23	-15,57	6,23	2,74***
PG	2	60,31	59,54	27,31	24,66	3,44	1,93*
	3	59,54	54,96	39,54			1,78*
	14	64,12	57,25	25,95			2,86***
	15	63,36	54,20	31,34			2,73***
T	11	63,36	58,02	35,75	47,33	15,53	3,07***
UTX	8	60,31	48,09	47,75	51,76	3,94	2,17**
VZ	1	60,31	47,33	18,99	10,44	-6,63	2,71***
	4	59,54	61,07	15,88			2,19**
	5	59,54	55,73	10,92			2,49***
	6	63,36	64,12	11,99			3,21***
	7	59,54	56,49	19,75			2,34***
	10	60,31	50,38	58,66			2,36***
WMT	15	61,83	47,33	17,67			3,09***
	8	57,25	67,94	16,29	-12,13	-4,99	1,72*
	11	61,83	70,23	-2,75			2,8***
	12	61,83	54,20	10,01			2,71***
	13	64,89	63,36	-4,78			3,42***
XOM	14	57,25	89,31	-1,61			1,68*
	4	60,31	62,60	68,46	67,66	24,84	1,81*
	7	61,07	54,96	86,02			1,74*

(***) Significativo al nivel de 1%
(**) Significativo al nivel de 5%
(*) Significativo al nivel de 10%