



UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS ECONÓMICAS Y ADMINISTRATIVAS  
ESCUELA DE ADMINISTRACIÓN

# **Técnicas Avanzadas Aplicadas a La predicción del Índice de Malasia**

Profesor guía: Dr. Antonino Parisi Fernández

Alumna: Pamela Jerez López

Santiago de Chile

JULIO 2007

## Índice

1.- Introducción	4
2.- Marco Teórico	6
2.1 Mercados Asiáticos	5
2.1.2 Economía de Malasia	6
2.1.3 Tendencias Macroeconómicas	7
2.1.4 Kuala Lumpur Composite Index y sus componentes	8
2.2 Reseña sobre las técnicas utilizadas	11
2.2.1 Algoritmos Genéticos	11
2.2.2 Redes Neuronales	15
2.2.3 Lógica Borrosa	20
3.- Datos y Metodología	22
3.1 Datos	22
3.2 Metodología	23
3.2.1 Modelo de Algoritmos Genéticos	23
3.2.1.1 Codificación y Población Inicial	24
3.2.1.2 Evaluación de la Predicción	24
3.2.1.3 Selección y Generación de Descendencia	25
3.2.2 Modelo de Redes Neuronales	26
3.2.2.1 Datos	27
3.2.2.2 Variable de Salida	27
3.2.2.3 Variables de Entrada	27
3.2.2.4 Evaluación de la Capacidad Predictiva de la Red Neuronal	27
3.2.3 Modelo de Lógica Borrosa	28
3.2.3.1 Datos	28
3.2.3.2 Variables de entrada:	29
4.- Resultados y conclusiones	31
4.1 Test de Acierto Direccional de "Pesaran y Timmerman"	31

4.2 Rentabilidad de las Técnicas Utilizadas	31
4.3 Resultados.	32
4.3.1 Resultado del Modelo de Algoritmo Genético	32
4.3.1.1 Mejor Resultado del Modelo de Algoritmo Genético	32
4.3.1.2 Significancia Estadística	33
4.3.1.3 Rentabilidad del Modelo Seleccionado	33
4.3.2 Resultado del Modelo de Redes Neuronales	33
4.3.2.1 Mejor Modelo de Redes Neuronales	34
4.3.2.2 Significancia Estadística	34
4.3.2.3 Rentabilidad del Modelo Seleccionado por la Red Neuronal	34
4.3.2.4 Resultado del Modelo de Lógica Borrosa	34
4.4 Conclusiones	35
5.- Referencias bibliográficas	37

## **1.- Introducción**

Continuamente las ciencias se esfuerzan para poder determinar los factores que nos afectan. En las últimas décadas se han desarrollado e implementado diferentes técnicas de predicción, las cuales pretenden satisfacer las necesidades de disminución de la incertidumbre y el riesgo, para poder enfrentar la toma de decisiones de la manera más eficiente y oportuna.

La creatividad de los agentes financieros ha permitido un amplio desarrollo de nuevos instrumentos de inversión o financiamiento, buscando con ello cubrir tanto necesidades como intereses de los usuarios. Esto ha llevado a que se destine grandes esfuerzos intelectuales con el objeto anticiparse a las variaciones de los activos y de romper con los paradigmas imperantes, es así como en la actualidad con la ayuda de la tecnología se han logrado importantes resultados que alimentan la esperanza de obtener beneficios vía predicción.

Efectivamente, en las últimas décadas se han desarrollado e implementado diferentes técnicas de predicción, las cuales pretenden satisfacer las necesidades de disminución de la incertidumbre y el riesgo, para poder enfrentar la toma de decisiones de la manera más eficiente y oportuna.

La fuerte competencia y los altos volúmenes transados han permitido a las ciencias, a través del desarrollo de nuevas tecnologías, entregar las herramientas apropiadas que permitan a las empresas ser competitivas y sostenibles en el tiempo.

En los últimos años, los avances tecnológicos han influido en la creciente utilización de la inteligencia artificial en los modelos financieros, de modo que a través de un proceso de autoalimentación que se gesta en el proceso de retroalimentación otorga la flexibilidad para simular con mayor precisión, en busca de homologar el comportamiento humano en la toma de decisiones.

El ámbito empresarial, también ha tenido un cambio importante debido al avance de las ciencias, ya que las nuevas tecnologías tratan de entregar las herramientas apropiadas que permitan a las empresas ser competitivas y sostenibles en el tiempo. Esto se ve reflejado en el campo de las finanzas, las cuales han experimentado profundos cambios, pasando de ser descriptiva, contable e institucional, a las finanzas “dinámicas” las cuales tratan de formular modelos que permitan explicar los fenómenos financieros.

Por lo tanto la inteligencia artificial, a través de la gestión del conocimiento y las técnicas de aprendizaje aplicadas a las finanzas, permitirán crear sistemas de información que serán relevantes para las decisiones financieras de las organizaciones.

Esta tesis se divide en 4 partes. El capítulo uno es la introducción, el capítulo dos hace una referencia al marco teórico, así como a las metodologías utilizadas en esta tesis. El capítulo tres muestra los datos y la metodología, y por último en el capítulo cuatro se presentan los resultados y las conclusiones.

## 2.- MARCO TEORICO

### 2.1 Mercados Asiáticos

Los mercados asiáticos han formado parte de la atención mundial en el último tiempo, debido a las rentabilidades generadas por los mismos en la década de los 90, la posterior crisis que los afectó y que tuvo repercusiones mundiales, y la actual recuperación que han tenido. Dada la experiencia ganada durante la crisis, los países asiáticos están reinventando sus economías, con la finalidad de implementar innovaciones tecnológicas. Para ello, requieren mercados de capital que faciliten su financiamiento, tal es el caso de Malasia y su Capital Putrajaya con los escenarios de High Tech, la Universidad de la Multimedia y el Proyecto MSC (super corredor multimedia), en los cuales, el gran promotor e impulsor de la iniciativa es el propio gobierno con una inversión de 1,000 millones de dólares en un fondo de financiamiento para tecno emprendedores.

Es por ello que, debido a esta expansión tecnológica, que nuestro objetivo de estudio se enfocará en el índice perteneciente a las cotizaciones bursátiles de la bolsa de Malasia, ***Kuala Lumpur Stock Exchange o KLSE*** (por sus siglas en inglés), también se conoce como ***Bursa Saham Kuala Lumpur o BSKL*** (por sus siglas en el idioma oficial de Malasia). Este índice lleva el nombre de ***Kuala Lumpur Composite Index (KLCI)***.

#### 2.1.2 ECONOMIA DE MALASIA

A continuación, se muestra información cuantitativa referente a la economía de Malasia. La moneda del país se denomina *Ringgit*. El país pertenece a las siguientes asociaciones de comercio: *ASEAN (Asociación de Naciones del Sudeste Asiático)*, *APEC (Foro de Cooperación Económica de Asia Pacífico)*, *WTO (Organización Mundial de Comercio)*. El producto interno bruto el año 2006 fue de \$308.8 billones, con un crecimiento de 5,9% con respecto al año anterior. El GDP per cápita se encuentra en el nivel de \$12.700 y, al analizarlo por sector, el GDP de 2006 se reparte en 8,3% en el área agrícola; 48,1% en el área industrial y 43,6% en el sector servicios.

La inflación durante el año 2006 alcanzó el nivel de 3.8%, la población bajo el límite de la pobreza representa un 5.1% de la población total, la fuerza laboral está compuesta por 10.73 millones de personas, las que se reparten de la siguiente forma: 13% en el sector agrícola, 36% en el sector industrial y un 51% en el sector servicios. El índice de desempleo durante 2006 se situó en un 3.5%.

Las principales industrias dentro de esta economía, se encuentran en el área de gomas y aceite de palma (procesamiento y manufactura), área electrónica y minas. Las exportaciones durante el año 2006 ascendieron a \$158.7 billones FOB y los principales destinos de ellas son: EEUU (16.63%), Singapur (13.86%), Japón (11.87%), China (8.79%), Tailandia (5.33%) y Hong Kong (4.34%). Por otra parte, las importaciones alcanzaron \$127. 3 billones FOB durante el 2006, siendo los principales proveedores: Japón (14.52%), EEUU (12.88%), Singapur (11.71%), China (11.6%), Corea del Sur (4.98%), Alemania (4.44%), Taiwán (5.52%) y Tailandia (5.27%).

### 2.1.3 TENDENCIAS MACROECONOMICAS

A continuación, se presenta un cuadro con la tendencia del Producto Interno Bruto de Malasia, a precios de mercado estimados por el Fondo Monetario Internacional, con cifras en millones de Ringgit Malayos.

Year	GDP (in millions)	Exchange (1 USD to MYR)	Inflation Index (2000=100)
1980	54,285	2.17	51
1985	78,890	2.48	64
1990	119,082	2.70	70
1995	222,473	2.50	85
2000	343,216	3.80	100
2005	494,544	3.78	109

Desde 1988 a 1997 la economía experimenta un período de amplia diversificación, de rápido y sostenido crecimiento, con un promedio de 9% anual.

Para 1999, el GDP Nominal per Cápita había alcanzado los \$3.238. La nueva inversión extranjera y la inversión doméstica jugaban un importante papel en la transformación de la economía del país. La manufactura creció desde un 13.9% del GDP en el año 1970 a un 30% en 1999, mientras la agricultura y minería que juntos alcanzaban un 42.7% del GDP en 1970, cayeron a 9.3% y 7.3% respectivamente en 1999.

La principal producción del país se concentra en: componentes electrónicos – Malasia es uno de los más grandes exportadores de aparatos semiconductores – y artículos electrónicos.

El rápido crecimiento fue logrado en parte a través de privatizaciones de ineficientes empresas estatales, las cuales, bajo presiones comerciales, fueron forzadas a utilizar de mejor manera sus recursos. Con estos niveles de crecimiento, los fondos extranjeros fueron atraídos a invertir en el mercado local. Esta oleada de inversiones creó la oportunidad para que los negocios locales aumentaran el capital en el índice KLSE, y además desarrollaran infraestructura en áreas como las telecomunicaciones. Esta intensa labor, creó empleos para millones de trabajadores extranjeros.

La influencia de las inversiones extranjeras hizo aumentar el índice KLSE sobre los 1.300 puntos en 1994 y el Ringgit sobre los 2.5 en 1997. En varias ocasiones, el índice KLSE llegó a ser el índice más activo del mundo, con volúmenes de transacción que superaban incluso al NYSE. La capitalización bursátil de las acciones componentes del índice estaba evaluada en \$181.236 millones en el año 2005. Esta valoración fue realizada por el Banco Mundial.

Algunos de los proyectos más visibles de esta época fueron: nuevo aeropuerto internacional (Kuala Lumpur International Airport), una planta hidroeléctrica (Bakun), las Torres Petronas y el Multimedia Super Corridor.

#### **2.1.4 KUALA LUMPUR COMPOSITE INDEX Y SUS COMPONENTES.**

La bolsa de comercio de Malasia (Kuala Lumpur Stock Exchange) inició sus transacciones oficialmente en el año 1960, teniendo dos sucursales: una en Singapur y la otra en Kuala Lumpur, las cuales se comunicaban entre sí por vía telefónica. En el año 1965, con la secesión entre Singapur y Kuala Lumpur, las transacciones accionarias continuaron utilizando el nombre de *Stock Exchange of Malaysia and Singapore (SEMS)*.

En 1973, con el termino del intercambio de moneda entre Malasia y Singapur, el SEMS fue dividido en el *Kuala Lumpur Stock Exchange Bhd (KLSEB)* y la *Stock Exchange of Singapore (SES)*. Las compañías malayas siguieron listadas en el SES y viceversa. En el año 1994, se adopta el nombre de *Kuala Lumpur Stock Exchange*.

El índice principal de la KLSE es el *Kuala Lumpur Composite Index*, el cual alcanzó la marca de los 1.000 puntos en Noviembre del año 2006. Por otra parte, este índice se ve afectado en gran medida por el resultado de los índices Nikkei y Dow Jones. Un efecto menor se produce con los índices FTSE, SESDAQ y Hang Seng.

A continuación, se muestra un listado con las 100 compañías que componen el índice KLCI:



**Figura 1:**

## Componentes del Malasia Stock Exchange

NO	STOCK CODE	SHORT NAME	COMPANY NAME
1	6599	AEON	AEON CO. (M) BHD
2	5185	AFFIN	AFFIN HOLDINGS BHD
3	5099	AIRASIA	AIRASIA BHD
4	1015	AMMB	AMMB HOLDINGS BHD
5	5076	ASTRO	ASTRO ALL ASIA NETWORKS PLC
6	1473	BRDB	BANDAR RAYA DEVELOPMENTS BHD
7	1562	BJTOTO	BERJAYA SPORTS TOTO BHD
8	5032	BIPORT	BINTULU PORT HOLDINGS BHD
9	4162	BAT	BRITISH AMERICAN TOBACCO (M) BHD
10	1023	COMMERZ	BUMIPUTRA-COMMERCE HOLDINGS BHD
11	1818	BURSA	BURSA MALAYSIA BHD
12	2836	CARLSBG	CARLSBERG BREWERY MALAYSIA BHD
13	2844	CIMA	CEMENT INDUSTRIES OF MALAYSIA BHD
14	2879	CCM	CHEMICAL COMPANY OF MALAYSIA BHD
15	7277	DIALOG	DIALOG GROUP BHD
16	6947	DIGI	DIGI.COM BHD
17	1619	DRBHCOM	DRB-HICOM BHD
18	3468	E&OPROP	E&O PROPERTY DEVELOPMENT BHD
19	5398	GAMUDA	GAMUDA BHD
20	3182	GENTING	GENTING BHD
21	7022	GTRONIC	GLOBETRONICS TECHNOLOGY BHD
22	1953	GHOPE	GOLDEN HOPE PLANTATIONS BHD
23	3255	GUINNESS	GUINNESS ANCHOR BHD
24	1503	GUOCO	GUOCOLAND (MALAYSIA) BHD
25	3034	HAPSENG	HAP SENG CONSOLIDATED BHD
26	5819	HLBANK	HONG LEONG BANK BHD
27	1597	IGB	IGB CORPORATION BHD
28	3336	UM	UM CORPORATION BHD
29	1961	IOICORP	IOI CORPORATION BHD
30	6289	SUNCITY	SUNWAY CITY BHD
31	5122	KENCANA	KENCANA PETROLEUM BHD
32	3492	KFC	KFC HOLDINGS (M) BHD

33	5089	KLCCP	KLCC PROPERTY HOLDINGS BHD
34	7164	KNM	KNM GROUP BHD
35	2445	KLK	KUALA LUMPUR KEPONG BHD
36	2003	KULIM	KULIM (M) BHD
37	3131	GUTHRIE	KUMPULAN GUTHRIE BHD
38	5097	KURASIA	KURNIA ASIA BHD
39	3794	LMCEMNT	LAFARGE MALAYAN CEMENT BHD
40	6645	LITRAK	LINGKARAN TRANS KOTA HOLDINGS BHD
41	2011	LINGUI	LINGUI DEVELOPMENT BHD
42	2887	LIONDIV	LION DIVERSIFIED HOLDINGS BHD
43	4235	LIONIND	LION INDUSTRIES CORPORATION BHD
44	1198	MAA	MAA HOLDINGS BHD
45	3735	MAGNUM	MAGNUM CORPORATION BHD
46	1155	MAYBANK	MALAYAN BANKING BHD
47	5014	AIRPORT	MALAYSIA AIRPORT HOLDINGS BHD
48	3786	MAS	MALAYSIAN AIRLINE SYSTEM BHD
49	5077	MAYBULK	MALAYSIAN BULK CARRIERS BHD
50	5525	MIDF	MALAYSIAN INDUSTRIAL DEV. FINANCE BHD
51	3832	MOX	MALAYSIAN OXYGEN BHD
52	3867	MPI	MALAYSIAN PACIFIC INDUSTRIES BHD
53	2488	MPLANT	MALAYSIAN PLANTATIONS BHD
54	1651	MRCB	MALAYSIAN RESOURCES CORPORATION BHD
55	5983	MBMR	MBM RESOURCES BHD
56	4502	MEDIA	MEDIA PRIMA BHD
57	3816	MISC	MISC BHD
58	8893	MKLAND	MK LAND HOLDINGS BHD
59	2194	MMCCORP	MMC CORPORATION BHD
60	3905	MULPHA	MULPHA INTERNATIONAL BHD
61	3999	NSTP	NEW STRAITS TIMES PRESS (M) BHD, THE
62	4006	ORIENT	ORIENTAL HOLDINGS BHD
63	5053	OSK	OSK HOLDINGS BHD
64	6866	BERNAS	PADIBERAS NASIONAL BHD
65	7108	PETRA	PETRA PERDANA BHD
66	5681	PETDAG	PETRONAS DAGANGAN BHD
67	6033	PETGAS	PETRONAS GAS BHD
68	5052	PLUS	PLUS EXPRESSWAYS BHD

69	4634	POSHLDG	POS MALAYSIA & SERVICES HOLDINGS BHD
70	4065	PPB	PPB GROUP BHD
71	5304	PROTON	PROTON HOLDINGS BHD
72	1295	PBBANK	PUBLIC BANK BHD
73	6807	PUNCAK	PUNCAK NIAGA HOLDINGS BHD
74	1066	RHBCAP	RHB CAPITAL BHD
75	8575	SAPCRES	SAPURACREST PETROLEUM BHD
76	2356	SARAWAK	SARAWAK ENTERPRISE CORPORATION BHD
77	7158	SCOMI	SCOMI GROUP BHD
78	1783	SPB	SELANGOR PROPERTIES BHD
79	5517	SHANG	SHANGRI-LA HOTELS (M) BHD
80	4324	SHELL	SHELL REFINING CO (F.O.M.) BHD
81	4197	SIME	SIME DARBY BHD
82	8664	SPSETIA	SP SETIA BHD
83	6084	STAR	STAR PUBLICATIONS (M) BHD
84	6165	SUNRISE	SUNRISE BHD
85	5012	TAANN	TA ANN HOLDINGS BHD
86	4898	TA	TA ENTERPRISE BHD
87	4405	TCHONG	TAN CHONG MOTOR HOLDINGS BHD
88	2267	TANJONG	TANJONG PUBLIC LIMITED COMPANY
89	4863	TM	TELEKOM MALAYSIA BHD
90	5347	TENAGA	TENAGA NASIONAL BHD
91	5103	TITAN	TITAN CHEMICALS CORP. BHD
92	7113	TOPGLOV	TOP GLOVE CORPORATION BHD
93	7000	TRANMIL	TRANSMILE GROUP BHD
94	7100	UCHITEC	UCHI TECHNOLOGIES BHD
95	1775	UEMWRLD	UEM WORLD BHD
96	4588	UMW	UMW HOLDINGS BHD
97	5005	UNISEM	UNISEM (M) BHD
98	5142	WASEONG	WAH SEONG CORPORATION BHD
99	4243	WTK	WTK HOLDINGS BHD
100	4677	YTL	YTL CORPORATION BHD

## 2.2 Reseña sobre las técnicas utilizadas

### 2.2.1 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<sup>1</sup>. 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. El Cuadro 1 contiene una explicación de la terminología usada.

<sup>1</sup> Al momento de aplicar un modelo de algoritmos genéticos, se debe identificar correctamente el problema de maximización o minimización a tratar. Si el problema en cuestión no es de ese tipo, se deberá buscar otro método para abordarlo.

CUADRO 1: Terminología en Algoritmos Genéticos

<b>Términos</b>	<b>Definiciones</b>
Entorno o Medio Ambiente	Función objetivo
Individuo o Ejemplar	Una de las posibles soluciones
Población	Conjunto de soluciones en un momento determinado
Generación	Nombre que identifica a la población, en un momento determinado
Cromosoma	Código Binario
Genes	Los bits que conforman el código binario

La secuencia de pasos que transforma los datos de entrada en datos de salida se describen a continuación.

- Paso 1: Codificación. 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).
- Paso 2: Definición del universo de variables explicativas del problema. Lo importante de la representación escogida es que debe ser capaz de representar todo el espacio de búsqueda que se desee investigar.
- Paso 3: Definición de la estructura del cromosoma que será manipulado por el algoritmo genético. Se define la representación binaria o código binario, es decir, el orden que las variables explicativas tendrán dentro de la estructura.
- Paso 4: Definición del tamaño de la población. Se determina el número de individuos que tendrá cada generación.
- Paso 5: Definición del número de generaciones. Se determina el número de generaciones a ser obtenidas durante el proceso. El tamaño de la población

multiplicado por el número de generaciones determina la cantidad de modelos a ser probados por el algoritmo genético.

- Paso 6: Definición de la primera generación. Determina el proceso de creación de los individuos para el primer ciclo del algoritmo genético. Normalmente la población inicial se forma a partir de individuos creados aleatoriamente.
- Paso 7: Definición de criterio de desempeño. Se define aquel criterio de desempeño mediante el cual serán seleccionados los individuos más aptos, generación tras generación, para que procreen la nueva descendencia.
- Paso 8: Ordenamiento. Los individuos o códigos binarios se ordenan de mejor a peor, según el criterio de desempeño escogido.
- Paso 9: Selección de individuos. Se debe definir un criterio de selección, mediante el cual un número de individuos de una generación se deberán reproducir para lograr la generación siguiente.
- Paso 10: Definición de número de individuos que pasan directamente a la nueva generación. Se debe definir cuántos individuos, de los mejores encontrados, pasarán directamente a la generación siguiente. Se busca que las mejores soluciones encontradas en una generación, vayan pasando directamente a la generación siguiente, asegurándose así que después de varios ciclos de evolución, la población final contenga a los individuos más aptos.
- Paso 11: Definición de un criterio de cruce o reproducción. Se debe definir cómo se realiza la combinación de dos individuos para obtener un descendiente. En otras palabras, se determina para el individuo descendiente cuántos y qué genes tendrá del padre y cuántos y qué genes tendrá de la madre.
- Paso 12: Mutación. Se aplica a los cromosomas creados a partir de la reproducción. Altera el contenido de una posición del cromosoma según una determinada probabilidad. Su objetivo es aumentar la diversidad de la población, evitando caer en un óptimo local.

- Paso 13: Se repiten secuencialmente, hasta obtener el número de generaciones definido, esto es: 1° búsqueda de resultados según criterio de desempeño, 2° ordenamiento, 3° reproducción, 4° mutación y 5° búsqueda de resultados según criterio de desempeño.

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 las distintas razones financieras. 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, aún 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. No obstante, y a diferencia de Allen & Karjalainen, en esta parte del estudio se analiza la capacidad de los modelos construidos por medio de algoritmos genéticos para proyectar el signo de la variación semanal del iShare EWZ y, en función de estas proyecciones, desarrollar estrategias de transacción. 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 accionario.

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, así como para determinar el tipo de selección y las probabilidades de los operadores genéticos, ya que no hay reglas fijas en esta materia.

### 2.2.2 Redes Neuronales

La teoría y modelamiento de redes neuronales está inspirada en la estructura y funcionamiento de los sistemas nerviosos cuando procesan información, donde la neurona biológica es el elemento fundamental.

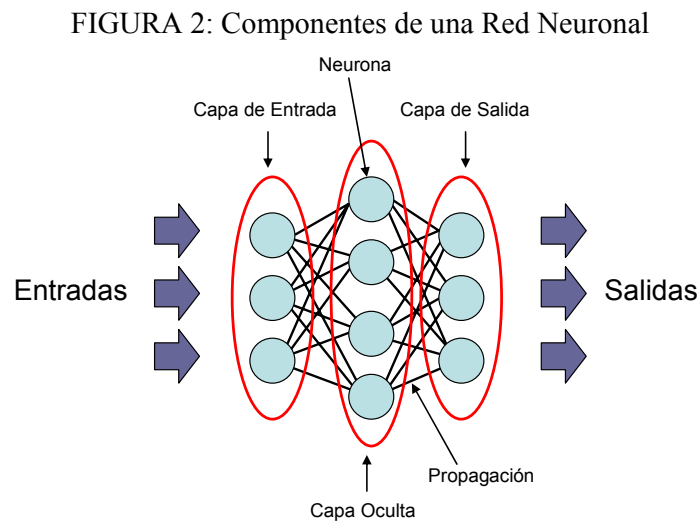
Las Redes Neuronales Artificiales (RNA) son modelos o sistemas de procesamiento que intentan reproducir la capacidad que tiene el cerebro humano para reconocer patrones, hacer predicciones o tomar una decisión en base a la experiencia pasada. Corresponden a un conjunto de algoritmos matemáticos que encuentran las relaciones no lineales entre conjunto de datos y suelen ser utilizadas como herramientas para la predicción de tendencias.

Los componentes de una RNA son los siguientes:

- Neurona: Es el componente básico en la RNA. Procesa un número de valores de entrada para producir un único valor de salida.
- Capa de Entrada: Es donde se recibe la información externa para la resolución del problema (variables independientes). Sus características son:
  - Debe ser de carácter única.
  - El número de neuronas queda definido por la cantidad de inputs.
  - Propaga los datos a la capa siguiente sin proceso alguno, salvo la aplicación de una función escalar.
- Capa Oculta: Es donde se lleva a cabo el procesamiento de los datos. Sus características son:
  - La existencia de varios tipos de arquitectura de red.
  - El número de neuronas es definido por quien aplica la red.
  - Puede existir más de una capa.

- Propaga los datos a la capa siguiente previa aplicación de una función de activación.
- Propagación:
  - Concepto referido al proceso de mover los datos desde una capa a la próxima en la Red Neuronal.
  - Los valores neuronales en la capa precedente son multiplicados por ponderadores al pasar a las neuronas de la capa siguiente.
- Capa de Salida: Es donde se presenta el resultado entregado por la Red Neuronal. Sus características son:
  - El número de neuronas es definido por la cantidad de outputs.
  - Las neuronas aplican una función de activación a los datos que reciben, antes de dar el producto final.

En la figura siguiente se indican los componentes señalados anteriormente.





Una RNA puede ser entendida como un modelo con cambio de régimen, donde el cambio se determina por una combinación lineal particular de los “ $p$ ” rezagos del vector  $X_t$ .

Sin embargo, en aplicaciones de RNA no se centra en la interpretación como modelo de cambio de régimen, sino en modelar la relación no lineal entre  $Y_t$  y  $X_t$ , donde  $X_t$  es el vector que contiene los “ $p$ ” rezagos de las variables explicativas del modelo, dentro de las cuales pueden considerarse rezagos de la propia variable  $Y_t$  y también variables exógenas.

$$Y_t = \phi_0 + \phi_1 \cdot G(X_t \gamma) + \varepsilon_t \quad (2)$$

Donde  $\varepsilon_t$  corresponde al error de predicción del modelo.

El funcionamiento de una RNA es bastante simple. Primero son ingresados los datos como inputs que pueden ser de índole científico, de mercado u otros; dichos datos son procesados por la red para finalmente entregar los resultados en forma de output de acuerdo a lo que se requiera, dependiendo de quién esté operando la red. Matemáticamente, el comportamiento de la neurona puede representarse por una lista de sus señales de entrada que son multiplicadas por sus pesos respectivos y posteriormente sumados. El resultado es llamado nivel de activación de la neurona, del cual depende la señal de salida que es enviada a cada una de las neuronas a las que está conectada a ella.

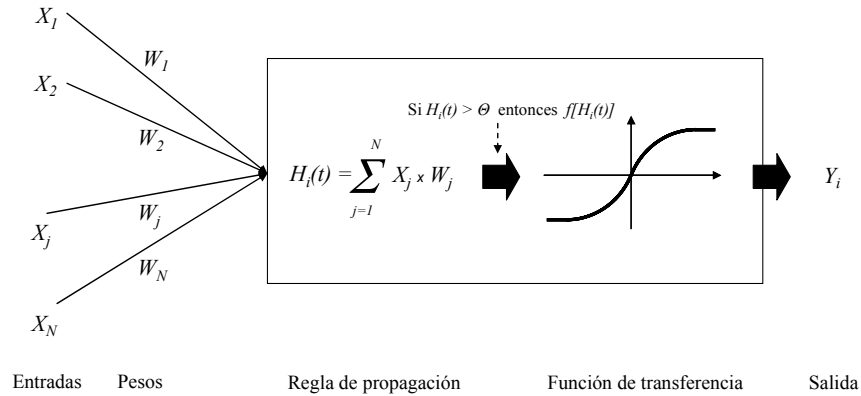
El modelo realiza una simplificación, averiguando cuáles son los elementos relevantes del sistema, ya sea porque la cantidad de información de que se dispone es excesiva, o bien porque es redundante.

Una elección adecuada de sus características, más una estructura conveniente, es el procedimiento convencional utilizado para construir redes capaces de realizar determinada tarea.

## Propagación de los Datos

Al llegar a la neurona todos los datos de las informaciones, ponderados por sus pesos, se suman. Esto es lo que se denomina Regla de Propagación.

FIGURA 3: Propagación de los Datos en una Red Neuronal



Podría adoptar otras fórmulas la Regla de Propagación, pero la más habitual es la simple suma de todas las entradas ponderadas, que toma el nombre de Potencial Sináptico.

$$H_i(t) = \sum_{j=1}^N X_j \times W_j$$

Donde:

- $H_i(t)$  el potencial sináptico de la neurona  $i$  en el momento  $t$ .
- $X_j$  la entrada de datos procedentes de la fuente de información  $j$ .
- $W_j$  el peso sináptico asociado a la entrada  $X_j$ .

Cuando el resultado de la Regla de Propagación supera un cierto número, denominado umbral, entonces la neurona se activa y el número resultante de la Regla de Propagación se “introduce” en una función denominada Función de Transferencia. Esquemáticamente se podría representar de la siguiente manera:

$$\text{Si } H_i(t) > \theta \text{ entonces } f[H_i(t)] \quad (4)$$

Se puede escoger diferentes funciones para la Función de Transferencia. Las cinco funciones de transferencia típicas que determinan los distintos tipos de neuronas son:

- Función Escalón.
- Función Lineal.
- Función Sigmoidea.
- Función Tangente Sigmoidea.
- Función Gaussiana.
- Función Gaussiana Complemento.

El resultado que nos ofrece cada una de estas funciones será el dato de salida de la neurona que se dirigirá, bien a otra neurona, bien al resultado final.

De esta manera, cada una de las capas contendrá un número determinado de neuronas en función del diseño que haya decidido el analista y del tipo de trabajo que vaya a realizar la red. Todas las neuronas que contiene una capa se conectan con todas las neuronas de la siguiente capa. Así, cuando una neurona obtiene un resultado, lo envía a todas las neuronas de la capa siguiente. Evidentemente ese resultado será ponderado por cada neurona por el peso sináptico.

### 2.2.3 Lógica Borrosa

La teoría de lógica borrosa fue introducida por Loffi A. Zadeh, a mediados de los años 60 (“Fuzzy Sets”) y desde esa fecha se ha desarrollado como una herramienta elemental para el control de subsistemas y procesos industriales complejos, ya que los sistemas borrosos permiten modelar sistemas no lineales y aprender de los datos haciendo uso de determinados algoritmos de aprendizaje. La lógica borrosa surge como un perfeccionamiento de la lógica booleana tradicional, en la cual los conjuntos son considerados como sistemas bivalentes, con sus estados alternando entre “pertenencia” o “no pertenencia” (inclusión o exclusión), donde tradicionalmente se define la función característica,  $f_A$  – que describe la pertenencia de un elemento  $x$  al conjunto  $A$  –, como:

$$f_A = \begin{cases} 1 & \text{si } x \in A \\ 0 & \text{si } x \notin A \end{cases} \quad (5)$$

De esta forma, la pertenencia de un elemento al conjunto  $A$  queda fraccionada y las relaciones entre conjuntos quedan categorizadas, siendo la transición entre dos conjuntos (o estados)  $A$  y  $B$ , radical e inmediata.

La lógica borrosa, por su parte, considera la idea de variable lingüística, que capta las propiedades de aproximación o los conceptos de imprecisión en un sistema, permitiendo que un elemento tenga valores intermedios en el grado de pertenencia a un conjunto determinado. Cada elemento del universo tiene asociado una función de pertenencia continua  $f_A$  – que toma valores entre 0 y 1 – que indica el “grado de pertenencia” del elemento  $x$  al conjunto  $A$ . Así, un conjunto en el universo de discurso  $U$  es definido por una función de pertenencia  $f_A: U \rightarrow [0, 1]$ , donde  $f_A(x) \in [0,1]$  indica el grado de pertenencia de  $x$  al conjunto  $A$ .

La lógica borrosa incorpora tres pasos fundamentales: (1) la elección de los inputs del proceso fuzzy, (2) la designación de funciones y conjuntos de pertenencia y, (3) la determinación de las reglas difusas y de la variable de salida (desfuzificación).

Los input del proceso fuzzy se refieren a las variables que se presumen importantes de considerar, ya que el comportamiento de éstas y sus combinaciones influyen sobre la variable que se desea proyectar. Estas variables son agrupadas en los conjuntos de

pertenencia (también llamados conjuntos difusos) a los cuales pertenecerán en algún grado.

Los conjuntos de pertenencia son determinados por sus funciones de pertenencia. Comúnmente, el número de conjuntos difusos es definido de manera tal que contenga todo el rango de posibles valores que podría adoptar la variable. Este rango de variación es conocido como universo de discurso. Las funciones de pertenencia generalmente son funciones continuas cuyo dominio es el conjunto de discurso y su imagen un valor real entre 0 y 1, el cual representará el grado de pertenencia de la variable al conjunto en cuestión. Estos conjuntos de pertenencia, junto a las reglas difusas, determinarán el comportamiento que tendrá la variable de salida.

Se requiere el establecimiento de reglas para combinar los conjuntos de pertenencia a través de operaciones de unión, intersección y complemento. Las operaciones entre conjuntos se asociarán a las conexiones lingüísticas “o”/“y”. Así, la intersección se asocia a “y”, mientras que la unión a “o”. De esta manera se pueden conectar y manipular los conjuntos de pertenencia que contienen los inputs para, a su vez, obtener nuevos conjuntos difusos en los cuales se agrupan los outputs. En principio, no existen reglas generales o un método de construcción de reglas fuzzy o de funciones de pertenencia, por lo que éstas son determinadas por cada diseñador. No obstante, éstas deben cumplir con las propiedades de t-normas para la intersección y t-conormas para la unión.

El proceso de proyección es realizado por medio de la elaboración de reglas difusas, las cuales relacionan la correspondencia entre los inputs y el output a través de las operaciones de conjuntos. La forma usual de las reglas difusas es del tipo: si  $i_1$  es  $f_1$  y/o  $i_2$  es  $f_2$  y/o...  $i_n$  es  $f_n$ , entonces  $o_t$  es  $o_k$ . Donde  $i_1, i_2, \dots, i_n$  son los inputs atribuibles a las funciones de pertenencias  $f_1, f_2, \dots, f_n$ , respectivamente;  $o_t$  es el output; y  $o_k$  es la clasificación atribuible a  $o_t$ . Finalmente, el output fuzzy debe ser transformado en una variable posible de interpretar, proceso denominado desfuzificación.

### 3. Datos y Metodología

#### 3.1 Datos

Para la realización del estudio, se tomaron 245 observaciones semanales<sup>2</sup> del cambio de precio del Índice de Malasia, correspondientes al período comprendido entre el 11 de Enero de 2002 y el 22 de Septiembre de 2006. Los modelos consideran como variable dependiente la primera diferencia porcentual del precio del índice de Malasia, correspondiendo ésta al período “ $t$ ” ( $\Delta Mal_t$ ) que representa el futuro inmediato (es decir, “one step ahead”).

Como variables exógenas se ha considerado el precio de cierre de distintos instrumentos, como acciones<sup>3</sup> (BHP), índices bursátiles<sup>4</sup> (IXIC y GPTSE), isahres<sup>5</sup> (EWC, EWZ y EWJ) y por último fondos de inversión cerrados<sup>6</sup> (IF e IFN).

#### Descripción De las Variables de Estudio

Símbolo	Descripción	Tipo Instrumento	Tipo Variable
KLSI	Chile Fund, Inc	Índice de Malasia	Dependiente
BHP	BHP Billiton Ltda.	Acción	Explicativa
IXIC	Nasdaq	Índice	Explicativa
GSPTSE	S&P500	Índice	Explicativa
EWC	Ishares MSCI Canadá Index	Ishare	Explicativa

<sup>2</sup> Se trabajó con valores de cierre semanales debido a que los administradores de fondos de inversión tienden a recomponer sus portafolios en función de pronósticos semanales.

<sup>3</sup> Acción: Título que representa una parte del capital social de una empresa. Suelen otorgar ciertos derechos a sus propietarios, entre otros, derecho a parte de los beneficios, a una cuota de la liquidación en caso de disolución, a voto en las juntas generales y derecho preferente de suscripción de acciones nuevas.

<sup>4</sup> Índice bursátil: Número índice que refleja la evolución de los precios de un conjunto de acciones a lo largo del tiempo. Suelen ser representativos de lo que sucede en un mercado determinado. Así un índice se diferenciará de otro en la muestra de valores que lo compongan, la ponderación de cada título, la fórmula matemática que se utilice para calcularlo, la fecha de referencia o base y los ajustes que se apliquen al mismo (por dividendos o modificaciones en el capital).

<sup>5</sup> iShares son grupos de acciones que se venden y compran en el Mercado como una acción individual, la cual, a la misma vez, trata de imitar los movimientos de un índice en particular.

<sup>6</sup> Fondo de inversión: Instrumento de inversión por el que un inversor o partícipe aporta o suscribe una cantidad de dinero que le da derecho a la propiedad de un porcentaje de la cartera del fondo (participación). Dicha cartera está formada por diversos activos y es administrada por una sociedad gestora.

EWZ	Ishares MSCI Brazil Index	Ishare	Explicativa
EWJ	Ishares MSCI Japan Index	Ishare	Explicativa
IF	India Fund, Inc	Fondo Inversión Cerrado	Explicativa
IFN	Indonesia Fund, Inc	Fondo Inversión Cerrado	Explicativa

### 3.2 Metodología

El presente trabajo utilizó tres modelos de técnicas avanzadas con el objeto de predecir el cambio de signo del instrumento en estudio, no así el cambio de precio en términos de cuantía. La importancia de esta predicción radica en la posibilidad de arbitrar si se tiene una mayor probabilidad de saber el rumbo que tomará el precio del instrumento, esto con un cierto grado de indiferencia del monto de la variación, dadas las grandes sumas de dinero que están en juego en cada transacción.

Los modelos utilizados se describen a continuación.

#### 3.2.1 Modelo de Algoritmos Genéticos

Se utilizó este modelo con el fin de analizar su eficiencia para encontrar un modelo multivariado dinámico que permitiera maximizar el porcentaje de predicción de signo (PPS) de las variaciones semanales del Índice de Malasia.

Estos modelos se basan en Algoritmo Genético simple que utiliza cadenas binarias de largo fijo en representación de las posibles soluciones al problema.

### **3.2.1.1 Codificación y Población Inicial**

Se utilizó ocho variables, cada una de las cuales se representó con un bit, estos bit representan el largo de la cadena binaria, por lo tanto el largo ella (8).

Si el número de soluciones posibles del modelo está dado por  $2^L$ , por lo tanto para nuestro modelo tendremos  $2^8$ , es decir, 256 modelos factibles para predecir el cambio de signo de la del Índice de Malasia, entre los cuales el algoritmo genético a través del proceso de optimización buscará la mejor solución.

### **3.2.1.2 Evaluación de la Predicción**

Para evaluar la calidad de los modelos se utilizó el PPS (porcentaje de predicción de signo) extramuestral, este resulta de la aplicación a una base de un conjunto de observaciones fuera de la muestra (extramuestral) de 145 observaciones.

Los modelos construidos a través de algoritmos genéticos se estimarán a través de mínimos cuadrados ordinarios y se evaluará su capacidad de predecir el cambio de signo del Índice.

Posteriormente se aplicará el Test de Pesaran y Timmerman, con el fin de medir de forma científica la significancia estadística de cada uno de los modelos analizados.

Luego se calculará la rentabilidad acumulada que se obtendría si se compra o vende cuotas de participación en el Índice de Malasia (asumiendo que se puede comprar un índice), siguiendo las recomendaciones de compra/venta que arrojó del modelo de predicción.



### 3.2.1.3 Selección y Generación de Descendencia

En esta fase, se utilizara el método aleatorio para asignar las probabilidades de selección a la población, usando como valor de calidad inicial el porcentaje de predicción de signo (PPS) de cada modelo. Esto permite que sólo los ejemplares más aptos pasen a la siguiente generación, es decir, el proceso de selección funciona a su vez como un filtro que identifica los peores ejemplares y les impide la reproducción, lo que impide la contaminación de las nuevas generaciones.

A través del Crossover<sup>7</sup>, se lleva a cabo la reproducción de los padres seleccionados, para dar origen a una nueva generación y así completar el tamaño de la población que se desea, 30 en nuestro caso. Para esto se seleccionó cuatro cromosomas padres para que generaran dos hijos, utilizando el operador de cruce de punto (Crossover) hasta completar el tamaño de población deseado.

La frecuencia de la mutación, que será aplicada al nuevo descendiente, será de una probabilidad de 8,33%.

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 cantidad, que consiste en un proceso de selección y generación de nuevas descendencias, que termina al lograr 10 generaciones.

---

<sup>7</sup> Crossover, operador genético que permite el intercambio de genes entre los cromosomas, en otras palabras permite la reproducción.

### **3.2.2 Modelo de Redes Neuronales**

El análisis se llevó a cabo a través de un modelo de redes neuronales multicapas con aprendizaje supervisado (permite una predicción mas flexible, cuando las variables son poco claras), específicamente la Red Ward<sup>8</sup>. Se utilizo este modelo de redes ya que se desempeñan bien como funciones de mapeo universal trabajando con series de tiempo (Díaz, 2005).

#### **3.2.2.1 Datos**

Para la aplicación de este modelo se consideraron las variaciones porcentuales (rentabilidades) de las observaciones semanales de las variables, para el periodo comprendido entre el 11 de Enero de 2002 y el 22 de Septiembre de 2006.

#### **3.2.2.2 Variable de Salida**

En el modelo formulado, la variable de salida esta dada por la primera diferencia (como variación porcentual) del Índice de Malasia, que es lo que se quiere proyectar, correspondiente al período “t”, el cual representa el futuro inmediato (one sep ahead).

#### **3.2.2.3 Variables de Entrada**

Las variables de entrada se referirán a las variaciones porcentuales de las variables explicativas optimizadas por el modelo de algoritmo genético estándar, analizado precedentemente. Por lo tanto, el modelo de redes neuronales que se analizó, incluye rezagos de las variables de entrada, para así considerar el desfase lógico que existe entre el momento en que se realiza la predicción, el período actual o (t-1) y el momento futuro para el cual la proyección es válida, al que nos referimos como período (t). Así, debido a que la información de hoy está desfasada con respecto a la proyección, se utilizan modelos dinámicos con rezagos en las variables independientes.

---

<sup>8</sup> La Red Ward se caracteriza porque pueden aplicarse diferentes funciones de activación a los slab de la capa oculta, para detectar diferentes características en los patrones procesados a través de la red, de esta manera, la capa de salida tiene diferentes puntos de vista de los datos, lo cual puede conducir a una mejor predicción.

De acuerdo a lo anterior, las variables de entrada son:

<b>Símbolo</b>	<b>Descripción</b>	<b>Tipo Instrumento</b>	<b>Tipo Variable</b>
GSPTSE	S&P500	Indice	Explicativa
EWZ	Ishares MSCI Brazil Index	Ishare	Explicativa
EWJ	Ishares MSCI Japan Index	Ishare	Explicativa
IFN	Indonesia Fund, Inc	Fondo Inversión Cerrado	Explicativa

### **Tipo de Red Neuronal, Arquitectura y Función de Activación**

En esta etapa se utilizó el modelo de Red Ward que usa el algoritmo de aprendizaje supervisado de propagación hacia atrás, para predecir el signo de la rentabilidad del Índice de Malasia. Este modelo se caracteriza porque en él, el resultado es conocido y la red se entrena a sí misma hasta que es capaz de predecir aquel resultado asociado con los datos de entrada (Dasgupta, Dispensa & Ghose, 1994).

Las funciones de la red neuronal ward utilizadas fueron:

- Función Tangente Hiperbólica, como capa de escalamiento
- Función Gaussiana, como capa de activación oculta
- Función Gaussiana Complemento, como capa oculta de activación
- Función Tangente Hiperbólica, como capa de salida

#### **3.2.2.4 Evaluación de la Capacidad Predictiva de la Red Neuronal**

El modelo de proyección descrito anteriormente 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 extramuestral, el cual se compone de 145 observaciones semanales. En esta etapa, el desempeño relativo del modelo fue medido por el número de predicciones correctas (hits) del signo del retorno de la acción. Así, la proyección extramuestral fue testeada 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, con el del valor observado, para cada  $i$ -ésima

observación del conjunto extramuestral ( $i=1,2,\dots, m$ ). 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. Este proceso se realizó para cada observación del conjunto extramuestral a través del método directo de proyección multi-etapa, por lo que no se evaluó la predicción del conjunto extramuestral en su totalidad de una sola vez, sino que se fue analizando una a una como parte de un proceso recursivo, metodología que ha sido empleada para medir el desempeño de modelos.

### **3.2.3 Modelo de Lógica Borrosa**

Este modelo fue ejecutado con distintos instrumentos financieros, por separado, como variable explicativa a fin de encontrar aquella que entregara la mejor predicción, el mejor PPS y la mayor estabilidad.

Cabe destacar que en este modelo aparte de utilizar las variables optimizadas en el modelo de algoritmos genéticos, se incorporó como variable explicativa el Índice de Precios Selectivo de Acciones (IPSA)

#### **3.2.3.1 Datos**

Para el desarrollo de este modelo se consideró un total de 245 observaciones, correspondientes al período comprendido entre el 11 de Enero de 2002 y el 22 de Septiembre de 2006. Considerando valores de cierre semanales.

### 3.2.3.2 Variables de entrada:

De acuerdo a lo descrito anteriormente, los instrumentos financieros utilizados como variable explicativa fueron:

<b>Símbolo</b>	<b>Descripción</b>	<b>Tipo Instrumento</b>	<b>Tipo Variable</b>
KLCI	Índice de Malasia	Índice Bursátil	Autoexplicativa
EWZ	Ishares MSCI Brazil Index	Ishare	Explicativa
EWJ	Ishares MSCI Japan Index	Ishare	Explicativa
IFN	Indonesia Fund, Inc	Fondo Inversión Cerrado	Explicativa
GSPTSE	S&P500	Índice Bursátil	Explicativa
IPSA	Índice de Precios Selectivo de Acciones	Índice Bursátil	Explicativa

### Variables de salida:

- Comprar
- Vender

### Etiquetas Lingüísticas

Se utilizó reglas construidas a partir de los valores de verdad generados por las siguientes etiquetas lingüísticas:

- Altísima
- Muy alta
- Alta
- Mas o menos alta
- Mas o menos baja
- Baja

- Muy baja
- Bajísima.

## **Reglas**

A partir de las etiquetas lingüísticas se crearon las siguientes reglas compra y venta del Índice de Malasia:

**Decisión de comprar si**, la variación de la variable explicativa fue “altísima”, “muy alta”, “alta” y “más o menos alta”, en el periodo “t”; también se comprará si al mismo tiempo la variable explicativa fue “altísima”, “muy alta”, “alta” y “más o menos alta”, en el periodo “t-1”, y por último se saca un promedio entre ambas reglas para explicar la decisión de compra.

**Decisión de Vender si**, la variación de la variable explicativa fue, “más o menos baja”, “baja”, “muy baja” y “bajísima” en el periodo “t”; también se venderá si sucede al mismo tiempo que la variación del periodo anterior (“t-1”) sea, “más o menos baja”, “baja”, “muy baja” y “bajísima”; considerando el máximo valor entre ambos explicar la decisión de venta.

## **Evaluación de la Capacidad Predictiva de la Red Neuronal**

Para verificar científicamente los resultados del modelo, se aplicará el Test de “Pesaran y Timmerman”, con el fin de medir la significancia estadística de los resultados arrojados por cada una de las variables explicativas utilizadas.

## **4.- Resultados y conclusiones**

### **4.1 Test de Acierto Direccional de “Pesaran y Timmerman”**

Se utilizó el test de acierto direccional de Pesaran & Timmerman (1992), para medir la capacidad predictiva y la significancia estadística de los modelos utilizados. El test de acierto direccional prueba la hipótesis nula de que las variaciones observadas están independientemente distribuidas de las variaciones proyectadas. Por ello, si se rechaza la hipótesis nula, se dice que existe evidencia estadística de que el modelo tiene capacidad para predecir la evolución futura de la variable observada.

El test 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 ( $i=1,2, \dots, m$ ), 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, aumentan la efectividad de la red, y en caso de no existir coincidencia, aumenta el error de predicción de la red.

### **4.2 Rentabilidad de las Técnicas Utilizadas**

La estimación de las rentabilidades permitirá identificar si la capacidad predictiva de las tres técnicas utilizadas generan o no beneficios económicos. Se calculó la rentabilidad acumulada que se hubiese logrado de haber seguido las recomendaciones de trading, compra o venta de los modelos. Se considero como una señal de compra cuando el valor proyectado del modelo indicara un alza en el precio y una recomendación de venta en caso contrario.

Para la estimación de las rentabilidades en las tres técnicas se asumió una inversión inicial de US\$10.000. Las rentabilidades no consideraron ventas cortas ni los costos de transacción.

Además las Rentabilidades obtenidas con las tres técnicas utilizadas fueron comparadas con una estrategia Buy and Hold para cada una de ellas.

### 4.3 Resultados.

#### 4.3.1 Resultado del Modelo de Algoritmo Genético

##### 4.3.1.1 Mejor Resultado del Modelo de Algoritmo Genético

El mejor resultado encontrado por el modelo de Algoritmo Genético para la predicción de signo del Índice de Malasia, se encuentra en la décima generación, donde alcanzó un PPS extramuestral de 64,83%, un PPS promedio de 64,51% y una menor varianza de 0,00009425.

El cuadro de resultados presentado más abajo, permite apreciar que a pesar que el PPS Extramuestral de 64,83% se logra a partir de la tercera generación, las generaciones posteriores demuestran ser cada vez mejores ya que se acorta el extremo inferior, es decir, el PPS mínimo es cada vez mayor. Lo anterior implica las últimas generaciones que se obtienen con la mutación de mejores cromosomas acercan cada vez más las proyecciones al optimo.

		PPS Prom	Varianza
1 generación	PPS Max 64,14% PPS Min 51,72%	57,70%	0,001080587
2 generación	PPS Max 64,14% PPS Min 53,10%	60,69%	0,000498585
3 generación	PPS Max 64,83% PPS Min 55,17%	61,79%	0,000680963
4 generación	PPS Max 64,83% PPS Min 53,10%	62,92%	0,001094637
5 generación	PPS Max 64,83% PPS Min 54,48%	63,86%	0,000582558
6 generación	PPS Max 64,83% PPS Min 54,48%	62,97%	0,001230555
7 generación	PPS Max 64,83% PPS Min 54,48%	62,78%	0,001316932
8 generación	PPS Max 64,83% PPS Min 57,24%	63,43%	0,000723222
9 generación	PPS Max 64,83% PPS Min 54,48%	63,98%	0,00055331
10 generación	PPS Max 64,83% PPS Min 60,69%	64,51%	0,00009425



El mismo cuadro nos permite apreciar que las cuatro mejores variables predictivas fueron, las siguientes:

<b>Símbolo</b>	<b>Descripción</b>	<b>Tipo Instrumento</b>	<b>Tipo Variable</b>
EWZ	Ishares MSCI Brazil Index	Ishare	Explicativa
EWJ	Ishares MSCI Japan Index	Ishare	Explicativa
IFN	Indonesia Fund, Inc	Fondo Inversión Cerrado	Explicativa
GSPTSE	S&P500	Indice Bursátil	Explicativa

#### **4.3.1.2 Significancia Estadística**

A pesar de lo alentadores resultados presentados por este modelo, el Test de Acierto Direccional (DA), con un resultado de  $-0,40$  no nos permite rechazar la hipótesis, ya que de acuerdo a éste, no se tendría capacidad predictiva, a un nivel de confianza del 95%.

#### **4.3.1.3 Rentabilidad del Modelo Seleccionado**

La rentabilidad acumulada que se alcanzó con el modelo seleccionado fue de un 97,81% versus la rentabilidad de la estrategia Buy & Hold, que alcanzó un 194,54%.

#### **4.3.2 Resultado del Modelo de Redes Neuronales**

Este modelo se corrió tres veces con 1.000, 5.000 y 10.000 iteraciones respectivamente y los resultados obtenidos son dicotómicos ya que el resultado de mejor PPS, no es el de mejor rentabilidad ni es validado estadísticamente. No obstante en los tres resultados se obtuvo estabilidad respecto de los PPS.

<b>Iteraciones</b>	<b>PPS Objetivo</b>	<b>PPS Intramuestral</b>	<b>PPS Extramuestral</b>	<b>Test DA</b>	<b>Rentabilidad</b>	<b>Buy And Hold</b>
1.000	55%	59,35%	59,84%	- 3,87	264,65%	194,54%
5.000	55%	60,16%	65,57%	- 0,84	85,39%	194,54%
10.000	55%	61,79%	62,30%	- 2,72	109,22%	194,54%

#### **4.3.2.1 Mejor Modelo de Redes Neuronales**

Evaluando el modelo encontramos que el mejor resultado para este modelo, se dio al correrlo con 1.000 iteraciones, con lo cual se obtuvo el PPS extramuestral de 59,84%, que aunque no es el PPS más alto que obtuvimos, queda respaldado por la mayor rentabilidad y la validez del test de Acierto Direccional (DAT).

#### **4.3.2.2 Significancia Estadística**

El test de Acierto Direccional (DA), para 1.000 y 10.000 iteraciones nos arroja que habría capacidad predictiva, estadísticamente significativa, con un 95% de nivel de confianza.

Por el contrario, el test de Acierto Direccional (DAT), para 5.000 iteraciones nos indica que, a un 95% de nivel de confianza, no hay evidencia estadísticamente significativa que nos permita rechazar la hipótesis ya que no habría capacidad predictiva.

#### **4.3.2.3 Rentabilidad del Modelo Seleccionado por la Red Neuronal**

La mejor rentabilidad acumulada generada por este modelo se alcanza al iterar 1.000 veces, logrando un 264,65%, siendo el único capaz de lograr una rentabilidad superior que la estrategia Buy & Hold, que alcanzó un 194,54%.

#### **4.3.2.4 Resultado del Modelo de Lógica Borrosa**

De acuerdo a los resultados obtenidos, que se presentan en el cuadro siguiente, El mejor resultado se obtiene con la variable explicativa IPSA, destacando por el elevado PPS extra muestral de 64,8%, con una rentabilidad de 265,8% y con capacidad predictiva según el test de Acierto Direccional (DAT). Recordemos que esta variable fue introducida arbitrariamente en este modelo a fin de verificar su impacto.

De las variables que nos han acompañado durante todo el trabajo, el el Índice Bursátil S&P500 (GSPTSE) el que arroja los mejores resultados, con un PPS extra muestral de 60,7%, una rentabilidad acumulada de 266,3% y con una capacidad predictiva estadísticamente

significativa. No podemos dejar de mencionar que la brecha entre los PPS intra y extra muestral no es despreciable y podría estar indicando una cierta inestabilidad.

La rentabilidad acumulada que se obtiene con todas las variables supera la rentabilidad que se podría obtener mediante la estrategia Buy & Hold.

Símbolo	PPS Intra	PPS Extra	Rentabilidad	DAT	Cap. Predictiva
CH	47%	53,8%	1.083,4%	-0,07	NO
EWZ	42%	60,7%	513,9%	0,00	NO
EWJ	48%	54,5%	336,7%	-0,23	NO
IFN	45%	58,6%	301,8%	0,12	NO
GSPTSE	54%	60,7%	266,3%	2,15	SI
IPSA	64%	64,8%	265,8%	4,14	SI

#### 4.4 Conclusiones.

En este estudio se aplicaron técnicas avanzadas, para la predicción del cambio de signo Índice de Malasia, a través de la construcción de modelos Multivariados Dinámicos, las técnicas utilizadas fueron: Algoritmos Genéticos, Redes Neuronales y Lógica Borrosa. El objetivo consistía en proyectar en el instante de tiempo “t-1”, el signo de variación que experimentaría el Índice de Malasia en el instante de tiempo “t”.

Los resultados obtenidos nos demuestran que efectivamente es posible predecir la variación del cambio de signo del índice de Malasia y que esta capacidad predictiva es validada estadísticamente según los resultados del test de acierto direccional de Pesaran & Timmermann (1992). Con lo cual una estrategia de trading basada en las recomendaciones de compra-venta dadas por los modelos permitiría obtener retornos relativamente más altos que una estrategia pasiva de Buy & Hold.

De las tres técnicas avanzadas de predicción utilizadas en este estudio, La Lógica Borrosa superaría la capacidad predictiva de los modelos de Algoritmo Genético y Redes Neuronales, ya

que sus resultados son mucho más consistentes en los tres parámetros de evaluación, a saber: PPS Extra Muestral, Rentabilidad y Test de Acierto Direccional de Pesaran & Timmermann. Con resultados de 64,8% para el PPS Extra Muestral, respaldado con un PPS Intramuestral de 64% que permite verificar la estabilidad del acierto, una rentabilidad de 265,76% que estaría por sobre la rentabilidad obtenida con la estrategia pasiva de Buy & Hold de 194,54% y estadísticamente significativo al momento de someterlo a la prueba DAT.

Cabe destacar que el más alto PPS Extramuestral se obtiene con el modelo de Red Neuronal, a 5.000 iteraciones, con un resultado de 65,57% en su mejor predicción, pero que no sería respaldado estadísticamente (-0,84) y con una rentabilidad, aunque económicamente positiva, no sería capaz de superar la obtenida con una estrategia pasiva, 85,39% v/s 194,54% respectivamente.

Para concluir el análisis del modelo de Redes Neuronales, sólo con 1.000 iteraciones superaría la rentabilidad de una estrategia pasiva, pero no presenta un PPS extra muestral destacable (59,35%), aunque si presentaría capacidad predictiva según la prueba estadística.

Para el caso del modelo de Algoritmos Genéticos, si bien presenta un significativo PPS Extra Muestral de 64,83%, no sería estadísticamente significativo a un 95% de confianza (-0,40) y una rentabilidad económicamente positiva, pero que no es capaz de superar la obtenida con una estrategia pasiva Buy & Hold.

Por último podemos concluir que el uso de modelos avanzados de predicción, de tipo flexibles y dinámicos, presentan efectivamente capacidad predictiva. En consecuencia y según los resultados del presente estudio, permiten superar a los modelos clásico o tradicionales de predicción. Lo anterior significa que de ser correctamente utilizados por las empresas permitiría la aplicación de estrategias de inversión más rentables.

## 5.- Referencias bibliográficas

- Allen, F. & Karjalainen, R. (1999). Using genetic algorithms to find technical trading rules. *Journal of Financial Economics*.
- 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.
- Brockett, P. W., Cooper W. W., Golden L. L. & Pitaktong U. (1994). A neural network method for obtaining an early warning of insurer insolvency.
- Chopra, N., Lakonishok J. & Ritter J. R. (1992). Measuring abnormal returns: Do stocks overreact.
- Conrad J. & Kaul G. (1988). Time-variation in expected returns. *Journal of Business* .
- Conrad J. & Kaul G. (1989). Mean reversion in short-horizon expected returns.
- DeBondt, W. F. M. & Thaler R. (1985). Does the stock market overreact?
- Fama, Eugene (1970). Efficient capital markets: A review of theory and empirical work.
- Fama, E. & French K. R. (1988). Permanent and temporary components of stock prices.
- Lo, A. & MacKinley A. C. (1988). Stock market price do not follow random walk: Evidence from a simple specification test.
- Parisi, Parisi, y Guerrero (2003), Modelos Predictivos De Redes Neuronales En Índices Bursátiles. *Trimestre Económico*. Vol LXX (4), núm 280, octubre-diciembre, pp. 721-744.
- Pesaran, M.H. & Timmermann A. (1992). A simple nonparametric test of predictive performance.
- Poterba, J. M. & Summers L. H. (1988). Mean reversion in stock prices: Evidence and implications.
- 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*.
- Material de Internet, en sitios como Corfo, Yahoo financieros, Google, SII, SVS e instituciones financieras de inversion nacionales e internacionales.