

Pontificia Universidad Católica de Valparaíso  
Facultad de Ingeniería  
Escuela de Ingeniería Informática

**REDES NEURONALES SIGMOIDAL CON  
ALGORITMO LM PARA PRONOSTICO DE  
TENDENCIA DEL PRECIO DE LAS ACCIONES DEL  
IPSA**

**PABLO ANDRÉS NEGRÓN BAEZ**

INFORME DE PROYECTO 2  
INGENIERÍA CIVIL INFORMÁTICA

Diciembre 2014

Pontificia Universidad Católica de Valparaíso  
Facultad de Ingeniería  
Escuela de Ingeniería Informática

**REDES NEURONALES SIGMOIDAL CON  
ALGORITMO LM PARA PRONOSTICO DE  
TENDENCIA DEL PRECIO DE LAS ACCIONES DEL  
IPSA**

**PABLO ANDRÉS NEGRÓN BAEZ**

Profesor Guía: **Nibaldo Rodríguez Agurto**

Profesor Co-referente: **José Miguel Rubio León**

Carrera: **Ingeniería Civil Informática**

Diciembre 2014

# Índice

Índice .....	i
Índice de Ilustraciones .....	iii
Índice de Tablas .....	iv
Índice de Ecuaciones .....	v
Resumen .....	vi
Abstract.....	vi
1. Introducción.....	1
2. Objetivos.....	2
2.1 Objetivo General.....	2
2.2 Objetivo Específicos.....	2
3. Pronosticadores neuronales.....	3
3.1 Pronosticadores neurales para el precio.....	3
3.2 Pronosticadores para la rentabilidad.....	6
3.3 Pronosticadores utilizando levenberg-marquardt.....	8
4. Redes neuronales artificiales.....	10
4.1 Descripción de red neuronal artificial.....	10
4.2 Redes neuronales de pronostico.....	11
4.3 Función de activación sigmoideal.....	11
4.4 Algoritmo Levenberg-Marquardt.....	12
5. Métodos de pronostico a largo plazo.....	14
5.1 Método directo.....	14
5.2 Método indirecto.....	14
6. Métricas de medición de modelos.....	15
7. Resultados.....	17
7.1 Resultados LAN.....	17
7.2 Resultados LAN producción diciembre - junio.....	21
7.3 Resultados COPEC.....	25
7.4 Resultados COPEC producción diciembre – junio.....	28
7.5 Resultados SANTANDER.....	32
7.6 SANTANDER producción junio - diciembre.....	35
8. Conclusión.....	39

9. Referencias .....	41
Anexos .....	43
A: Empresas que participan en el IPSA 2014.....	44

## Índice de Ilustraciones

Ilustración 1: Red Neuronal Artificial.....	10
Ilustración 2: Grafica de función sigmoïdal.....	12
Ilustración 3: Algoritmo LM.....	13
Ilustración 4: Gráfico GCV LAN, primer día.....	18
Ilustración 5: Gráfico de correlación LAN, Primer día.....	18
Ilustración 6: Gráfico valor real v/s valor estimado LAN, Primer día.....	19
Ilustración 7: Gráfico dispersión LAN, Primer día.....	19
Ilustración 8: LAN valor real v/s Pronosticado, quinto día.....	20
Ilustración 9: LAN Grafico dispersión, quinto día.....	20
Ilustración 10: Gráfico estimado v/s valor real junio directo.....	21
Ilustración 11: Gráfico de correlación LAN, Primer día.....	21
Ilustración 12: LAN valor real v/s Pronosticado, indirecto junio.....	22
Ilustración 13: LAN Grafico dispersión, indirecto junio.....	22
Ilustración 14: LAN valor real v/s Pronosticado, diciembre 2013.....	23
Ilustración 15: LAN Grafico dispersión, diciembre 2013.....	23
Ilustración 16: LAN valor real v/s Pronosticado, indirecto diciembre 2013.....	24
Ilustración 17: LAN Grafico dispersión, indirecto diciembre 2013.....	24
Ilustración 18: Gráfico GCV COPEC, primer día.....	25
Ilustración 19: Gráfico de correlación COPEC, primer día.....	25
Ilustración 20: Gráfico valor real v/s pronosticado COPEC, primer día.....	26
Ilustración 21: Gráfico dispersión COPEC.....	26
Ilustración 22: COPEC valor real v/s Pronosticado, quinto día.....	27
Ilustración 23: COPEC Grafico dispersión, quinto día.....	27
Ilustración 24: Gráfico GCV COPEC, directo junio.....	28
Ilustración 25: Gráfico de correlación COPEC, directo junio.....	28
Ilustración 26: COPEC valor real v/s Pronosticado, indirecto junio.....	29
Ilustración 27: COPEC Grafico dispersión, indirecto junio.....	29
Ilustración 28: COPEC valor real v/s Pronosticado, directo diciembre.....	30
Ilustración 29: COPEC Grafico dispersión, directo diciembre.....	30
Ilustración 30: COPEC valor real v/s Pronosticado, indirecto diciembre.....	31
Ilustración 31: COPEC Grafico dispersión, indirecto diciembre.....	31

Ilustración 32: Gráfico GCV Santander, Primer día .....	32
Ilustración 33: Gráfico de correlación Santander, Primer día.....	32
Ilustración 34: Gráfico valor real v/s pronosticado Santander, Primer día .....	33
Ilustración 35: Gráfico dispersión Santander, Primer día .....	33
Ilustración 36: Santander valor real v/s Pronosticado, quinto día.....	34
Ilustración 37: Santander Grafico dispersión, quinto día.....	34
Ilustración 38: Gráfico GCV Santander, directo junio 2014.....	35
Ilustración 39: Gráfico de correlación Santander, directo junio 2014 .....	35
Ilustración 40: Santander valor real v/s Pronosticado, indirecto junio 2014 .....	36
Ilustración 41: Santander Grafico dispersión, indirecto junio 2014.....	36
Ilustración 42: Santander valor real v/s Pronosticado, directo diciembre 2013.....	37
Ilustración 43: Santander Grafico dispersión, directo diciembre 2013.....	37
Ilustración 44: Santander valor real v/s Pronosticado, indirecto diciembre 2013.....	38
Ilustración 45: Santander Grafico dispersión, indirecto diciembre 2013.....	38

## Índice de Tablas

Tabla 1: Comparación de métricas obtenidas [1].....	3
Tabla 2: Resultados obtenidos [2].....	4
Tabla 3: Resultados obtenidos [3].....	5
Tabla 4: Resultados de retorno del modelo CBDWNN [8] .....	5
Tabla 5: VAMA EMV y NN [4].....	6
Tabla 6: Resultados a corto plazo [5].....	7
Tabla 7: Resultados a plazo medio [5].....	7
Tabla 8: Resultados a largo plazo [5].....	7
Tabla 9: Comparación de resultados de diferentes métodos [12] .....	8
Tabla 10: Mejores resultados de pronostico RNA LM [9].....	9
Tabla 11: numero de intentos para converger [13] .....	9
Tabla 12: Mejor resultado LAN primer día .....	17
Tabla 13: Mejor resultado LAN quinto día.....	20
Tabla 14: Mejor resultado LAN método directo junio 2014.....	21
Tabla 15: Mejor resultado LAN método indirecto junio 2014.....	22
Tabla 16: Mejor resultado LAN directo diciembre 2013.....	23

Tabla 17: Mejor resultado LAN indirecto diciembre 2013 .....	24
Tabla 18: Mejor resultado COPEC, Primer día .....	25
Tabla 19: Mejor resultado COPEC quinto día .....	27
Tabla 20: Mejor resultado COPEC, directo junio 2014 .....	28
Tabla 21: Mejor resultado COPEC indirecto junio 2014 .....	29
Tabla 22: Mejor resultado COPEC directo diciembre 2013 .....	30
Tabla 23: Mejor resultado COPEC indirecto diciembre 2013 .....	31
Tabla 24: Mejor resultado Santander primer día .....	32
Tabla 25: Mejor resultado Santander quinto día .....	34
Tabla 26: Mejor resultado Santander directo junio 2014 .....	35
Tabla 27: Mejor resultado Santander indirecto junio 2014 .....	36
Tabla 28: Mejor resultado Santander directo diciembre 2013 .....	37
Tabla 29: Mejor resultado Santander indirecto diciembre 2013 .....	38

## Índice de Ecuaciones

Ecuación 1: Ecuación función sigmoïdal .....	12
Ecuación 2: Derivada de función sigmoïdal .....	12
Ecuación 3: Ecuación del algoritmo de gauss-newton .....	12
Ecuación 4: Ecuación algoritmo levenberg-marquardt .....	13
Ecuación 6: Ecuación RMSE .....	15
Ecuación 7: Ecuación MAPE .....	15
Ecuación 8: Ecuación MAE .....	15
Ecuación 9: Ecuación coeficiente de determinación .....	16
Ecuación 10: Ecuación GCV .....	16

## **Resumen**

En el presente proyecto de título, se presenta un modelo de predicción para acciones del IPSA basado en Redes Neuronales Artificiales (NRA) con función de activación sigmoïdal. Para el entrenamiento de la NRA es utilizado el algoritmo de aprendizaje levenberg-marquardt (LM). Este algoritmo minimiza una función sobre un cierto espacio de posibles soluciones. La estrategia de aprendizaje del pronóstico neuronal está basada sobre el método directo e indirecto para predecir el precio de cinco días futuros. La fase de calibración del modelo neuronal fue usando las acciones de las empresas de LAN, SANTANDER y COPEC para el período entre enero-2010 y noviembre-2013, mientras que la fase de validación fue realizada para el período diciembre-2013 a junio-2014. Los resultados obtenidos durante la etapa de validación usando el pronosticador neuronal basado en el método indirecto superaron en un 67% en exactitud al método directo.

## **Abstract**

In the present degree Project, we present a forecasting model for IPSA index stocks base on artificial neural networks (ANN) with a sigmoïdal activation function. For the training phase the ANN we use de levenberg-marquardt algorithm (LM). This algorithm minimize a function over a space of possible solutions. the strategy of the learning of the neural forecasting is based on the direct and indirect method for forecasting the value of the stock for the next 5 days. the phase of the calibration of the method was using the stocks of three enterprises LAN, COPEC and SANTANDER for the period between january 2010 and november 2013, while the validation phase was made for december 2013 and june 2014. the result obtained during the validation phase using the neural forecasting base on the indirect method overcome in 67% the results of the direct method.

# 1. Introducción

El Índice de Precios Selectivo de Acciones (IPSA)[10] es el principal índice bursátil de Chile, calculado desde 1977 y elaborado por la cámara de comercio de Santiago. Corresponde a un indicador de rentabilidad con las 40 S.A. que tienen mayor presencia bursátil en el año y que supere los US\$ 200.000.000 de capital. En su cálculo el índice considera todas las variaciones de capital de cada acción incluida en el índice, ponderada por el peso relativo de cada una de ellas, siendo dicho peso calculado a partir de una fórmula que considera, tanto la capitalización bursátil, como el número de transacciones y la libre flotación.

El índice ofrece bastante seguridad a los inversionistas, especialmente en las empresas de servicios públicos básicos como el agua, electricidad y comunicaciones; muchas de estas empresas se encuentran con mayor ponderación en el índice. El índice fue el más rápido en recuperarse en América Latina luego de la crisis mundial.

Las acciones son instrumentos de renta variable que favorecen a ambas partes involucradas en su transacción, por un lado el comprador pasa a ser dueño de una fracción de la empresa que emite la acción y a esta última le sirve como alternativa de financiamiento. Desde el punto de vista del comprador, las acciones son elementos de ahorro a corto, mediano, largo plazo o bien plazo indefinido dependiendo del motivo que le insto a comprar la acción. Es por esto que uno de los aspectos más importantes y a la vez más complejos en el mercado bursátil es ser capaz de determinar cuándo comprar o vender una acción para obtener, ya sea, la máxima ganancia o la mínima pérdida.

Predecir el movimiento del precio de las acciones ha sido ampliamente estudiado, a través de análisis fundamental y análisis técnico, de este podemos mencionar uso de algoritmos genéticos, maquinas de soporte vectorial, redes neuronales artificiales, modelos difusos, análisis cuadrático de discriminante, análisis lineal de discriminante, naïve bayes[11] por nombrar algunas, todas dando buenos resultados y encontrándose a día de hoy en constante mejora.

En el siguiente estudio, se exponen diferentes técnicas para pronosticas el comportamiento de las acciones, se verán varios estudios de diferentes autores, de ellos se analizaran y se extrapolara información con el fin de encontrar la técnica mas adecuada para el pronostico de este índice.

La necesidad de hacer un buen pronostico del valor que tomaran las acciones del IPSA, es para que todas las personas sin tener conocimiento del funcionamiento del mercado de acciones, puedan tener una buena oportunidad de hacer dinero participando del mercado de acciones, ya que finalmente este modelo solo pedirá datos anteriores los analizará y pronosticará si el valor de la acción subirá o bajará, para que el inversionista decida si debe vender, comprar o mantener la acción.

## **2. Objetivos**

A continuación se presentarán los objetivos planteados para este proyecto. Por un lado se mencionará el objetivo general del proyecto, seguido por los objetivos específicos que sirven de apoyo para la obtención del objetivo general.

### **2.1 Objetivo General**

Desarrollar un modelo uni-variado para pronosticar la tendencia del precio de tres acciones del IPSA usando una red neuronal artificial con aprendizaje basado en el algoritmo de Levenberg-Marquardt.

### **2.2 Objetivo Específicos**

- Explicar la estructura de una RNA y la funcionalidad del algoritmo de LM.
- Diseñar y estimar los parámetros del pronosticador neuronal usando el algoritmo LM combinado con el método de predicción directo e indirecto.
- Evaluar la exactitud del pronosticador neuronal usando métricas residuales.

### 3. Pronosticadores neuronales.

A continuación se presentaran una serie de estudios donde se analizan diferentes tipos de modelos de pronósticos, existen 3 categorías modelos de pronostico utilizando redes neuronales para el precio de una acción, modelos de pronostico utilizando redes neuronales para el retorno de una acción y modelos de pronostico utilizando algoritmo levenberg-marquardt.

#### 3.1 Pronosticadores neurales para el precio

Según los estudios realizados por Qing Caoa, Karyl B. Leggioa y Marc J. Schniederjans[1]. Es posible predecir el movimiento del precio de las acciones del mercado de shanghai utilizando redes neuronales de una variable o multivariable y modelos lineales que fueron comparados con pronósticos lineales extraídos de literatura de pronostico financiero. Se pudo comprobar que las redes neuronales son una gran herramienta para la predicción de mercados emergentes. Se comprobó que un modelo simple de una variable tiene mejores resultados que un modelo multivariable.

	Overall			
	MAD	MAPE	MSE	SD
UVL	0.0177	0.5636	0.5259	0.1724
MVL	0.0198	0.6123	0.5728	0.2223
UANN	0.0130	0.3437	0.2951	0.1247
MANN	0.0139	0.4102	0.3964	0.1435

Tabla 1: Comparación de métricas obtenidas [1]

Panayiotis C. Andreou, Chris Charalambous, Spiros H. Martzoukos[2]. Compararon la habilidad de las paramétricas de black y scholes, los modelos de corrado y red neuronal artificial para calcular el precio de las opciones europeas del S&P 500. Se utilizaron parámetros históricos e implícitos. Se creó un modelo híbrido donde se incorporó información de los modelos paramétricos a la red neuronal. Los resultados difieren de otros resultados encontrados en otros estudios. Probaron que la red neuronal híbrida de black y scholes superaron a la red neuronal estándar.

	Short	Medium	Long	Short	Medium	Long
	$BS_{con}^P$			$CS_{con}^P$		
<i>Results for the full dataset</i>						
VDOTM	3.60	4.91	0.56	8.34	10.61	0.66
DOTM	2.27	4.50	2.82	3.02	5.24	4.47
OTM	5.78	8.37	3.97	6.29	9.68	5.08
JOTM	7.81	6.68	6.15	8.13	7.64	7.65
ATM	6.67	9.46	5.86	7.30	10.14	7.29
JITM	6.71	9.41	4.34	7.29	9.21	5.97
ITM	7.70	7.13	4.43	8.24	7.59	5.18
DITM	7.07	7.93	7.27	7.20	8.50	7.50
VDITM	8.26	9.46	8.74	8.29	10.05	9.05
	$BS_{con}^{Mh^*}$			$CS_{con}^{Mh^*}$		
VDOTM	3.60	4.97	1.15	6.13	10.22	6.04
DOTM	2.46	4.83	2.32	2.96	5.28	5.03
OTM	5.50	7.75	3.98	6.19	9.41	5.36
JOTM	5.89	5.36	5.78	7.83	7.30	7.66
ATM	4.73	8.18	5.38	6.94	9.86	7.13
JITM	5.59	7.39	4.10	6.89	8.68	6.64
ITM	6.24	6.05	3.95	7.58	7.16	5.69
DITM	5.80	7.15	6.74	6.64	8.04	7.17
VDITM	8.03	9.29	8.46	8.96	10.33	9.26
<i>Results for the reduced dataset</i>						
	$BS_{con}^{Mh^*}$			$CS_{con}^{Mh^*}$		
VDOTM	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.
DOTM	2.36	4.07	n.a.	2.54	5.22	n.a.
OTM	5.08	7.25	n.a.	5.69	8.74	n.a.
JOTM	5.82	5.59	n.a.	6.76	7.09	n.a.
ATM	4.65	8.37	n.a.	5.68	9.53	n.a.
JITM	5.50	7.68	n.a.	6.20	8.16	n.a.
ITM	5.98	5.84	n.a.	6.73	6.75	n.a.
DITM	5.45	6.59	n.a.	5.95	7.67	n.a.
VDITM	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.

Tabla 2: Resultados obtenidos [2]

Se han aceptado muchos estudios donde dicen que en los mercados financieros no existe una linealidad y que por lo mismo una red neuronal puede pronosticarlos. Pero muchos estudios no consideran la relevancia de las variables de entrada, o cuando se cambia el modelo de mercado financiero o la estrategia a utilizar en el mercado. David Enke, Suraphan Thawornwong[3], proponen en este estudio utilizar data mining para evaluar las relación entre numerosas variables financieras y económicas. Se utilizan redes neuronales para que una vez encontrada las variables, utilizando data mining, se pueda analizar el pronostico que puedan entrar como conjunto de variables. El estudio se basa principalmente en la parte del pronostico, que es lo que se quiere encontrar. Los resultados encontrados fueron los siguientes:

		Monthly Return	Std. of Return	Sharpe Ratio	Equal-variance
NN Level Estimation Models	Original Level NN	1.55	3.56	0.33	1.20
	Portfolio Level NN	1.58	3.61	0.34	1.20
	GRNN	1.47	3.64	0.30	1.12
	Sign Port Level NN	1.62	3.55	0.35	1.25
NN Classification Models	Original Class NN	1.51	2.99	0.38	1.32
	Portfolio Class NN	1.72	3.16	0.43	1.43
	PNN	1.26	2.67	0.33	1.20
Benchmark	Regression	0.89	2.49	0.21	0.89
	Buy-and-Hold	1.54	3.68	0.32	1.16
	T-bill	0.37	-	-	-

**Tabla 3: Resultados obtenidos [3]**

En el 2009, Pei-Chann Chang, Chen-Hao Liu, Jun-Lin Lin, Chin-Yuan Fan, Celeste S.P. Ng.[8] lograron pronosticar el movimiento que tomaría una acción combinando ventanas de tiempo dinámico, razonamiento basado en casos y redes neuronales, utilizaron una ventana dinámica basada en casos con back-propagation para minimizar un falso positivo de comprar o vender una acción. Se pudo ver el precio de una acción cualquiera sin importa la relevancia que tenga esta en el mercado.

Tres etapas se necesitaron para lograr resultados (1) descartaron las acciones potenciales, (2) utilizaron una red back-propagation para predecir en que punto se debe comprar o vender de acuerdo al precio de la acción y (3) para ratificar el pronostico de la red neuronal de back-propagation y con esto reducen los falsos positivos de comprar o vender.

Company		Rate of return (%)		
		CBR	BPN	CBDWNN
Upward	AUO	65.70	71.47	96.59
	EPISTAR	204.42	213.57	282.49
	GP	67.08	66.18	93.57
Steady	FOXLINK	38.25	36.93	73.46
	COMPAL	31.35	24.3	37.75
	UMC	26.54	33.45	78.46
Downward	SIS	39.32	53.17	65.20
	SENAO	31.90	34.73	46.62
	D-LINK	21.49	37.55	51.48

**Tabla 4: Resultados de retorno del modelo CBDWNN [8]**

### 3.2 Pronosticadores para la rentabilidad

Se ha aprobado que el volumen de operaciones proporciona información para entender el movimiento del precio de las acciones. A partir de eso, equivolume charting fue desarrollado, ya que las acciones se mueven aparentemente en un rango de volumen de referencia que es opuesto al cuadro de referencia de tiempo. Se crearon 2 indicadores para analizar esto VAMA (volume adjusted moving average) y EMV (ease of movement volume) se crearon a partir del equivolume charting.

Thira Chavarnakul, David Enke[4] desarrollaron un modelo que explore la rentabilidad del mercado de acciones usando una red neuronal que pueda asistir la toma de decisiones de los indicadores VAMA y EMV. Es una red neural de regresión generalizada (GRNN), esta red es utilizada para pronosticar el precio futuro de las acciones. Para que la modelo neuronal pueda predecir los precios de esta forma también debe predecir el valor de EMV. Con esto se espera que los corredores de bolsa puedan entrar y salir antes de el movimiento de la curva de las acciones cambio su curso.

El resultado obtenido fue que el modelo de red neuronal artificial arroja mejores predicciones que solamente usar el modelo equivolume charting. 2 redes neuronales fueron utilizadas para calcular el precio de cierre de las acciones del día siguiente y también para calcular el tamaño del equivolume. Los resultados fueron los siguientes:

CP and interval	VAMA		EMV and VAMA		EMV with the NN and VAMA		Buy-and-hold	
	Gain/loss	# Trades	Gain/loss	# Trades	Gain/loss	# Trades	Gain/loss	# Trades
CP and 5	-\$38.69	90	\$89.69	32	\$220.30	20	\$201.00	2
CP and 21	\$72.63	38	\$86.80	12	\$258.54	4	\$201.00	2
CP and 55	\$158.00	22	\$202.98	4	\$243.64	2	\$201.00	2
Average	\$63.98	50	\$126.49	16	\$240.83	8.67	\$201.00	2

**Tabla 5: VAMA EMV y NN [4]**

Estudios recientes muestran que hay un significativo casualidad no lineal bidireccional entre las ganancias con la compra de acciones y el volumen de operaciones. En esta investigación, Xiaotian Zhu , Hong Wang, Li Xu , Huaizu Li[5]. avalaran esta afirmación y se mostrara que el uso de redes neuronales puede pronosticar el movimiento de acciones a corto medio y largo plazo. Se utilizaran varias combinaciones diferentes de índices y componente del volumen de operaciones. La red neuronal se entrenara con ganancias de acciones y volumen de ella de índices como NASDAQ, DIJA y STI.

Este estudio implementa una red neuronal feed-forward de 3 capas como el modelo básico de pronostico, agregando diferentes selecciones de entrada de volumen de operaciones. A diferencia de lo que se pensaba con anterioridad los resultados de esta investigación entregaron que el volumen de operaciones no influye mayormente en el pronostico a corto plazo. Esto puede ser debido a que el nivel de ruido y la alta volatilidad de los datos diarios que atenúan de una forma no lineal entre las acciones y el volumen de operaciones. Pero si se pudo comprobar que si influye claramente en el pronostico a medio y largo plazo. Con selección de entradas adecuadas, se pueden lograr mejoras significantes solo por incluir el componente de volumen de operaciones al modelo básico para el pronostico a largo plazo.

NNs models	DJIA				NASDAQ				STI			
	M1	M2	M3	M4	M1	M2	M3	M4	M1	M2	M3	M4
5	0.70 (0.26)	0.56 (0.22)	0.59 (0.24)	1.17 (0.25) <sup>a</sup>	1.64 (0.06)	1.76 (0.63)	1.66 (1.23)	2.17 (0.32) <sup>a</sup>	0.74 (0.03)	0.77 (0.01)	0.92 (0.23)	0.86 (0.12)
10	0.59 (0.19)	0.61 (0.23)	1.19 (0.28) <sup>a</sup>	0.67 (0.31)	1.96 (1.66)	1.82 (1.32)	3.84 (0.98) <sup>a</sup>	2.23 (1.42)	0.78 (0.44)	0.84 (0.15)	1.06 (0.23)	1.52 (0.24) <sup>a</sup>
15	0.65 (0.18)	1.60 (0.23) <sup>a</sup>	1.07 (0.20)	0.77 (0.27)	3.41 (3.21)	2.47 (1.11) <sup>b</sup>	2.58 (0.78)	2.74 (1.45)	1.11 (0.23)	1.43 (0.24)	0.97 (0.39)	2.04 (0.13) <sup>a</sup>
20	0.82 (0.24)	1.00 (0.25)	0.86 (0.27)	0.88 (0.19)	2.58 (0.86)	2.64 (1.23)	2.97 (1.76)	2.82 (1.23)	0.92 (0.38)	1.07 (0.43)	2.03 (0.23)	3.03 (0.21) <sup>a</sup>

**Tabla 6: Resultados a corto plazo [5]**

NNs models	DJIA				NASDAQ				STI			
	M1	M2	M3	M4	M1	M2	M3	M4	M1	M2	M3	M4
5	2.61 (0.34)	2.42 (0.31)	2.39 (0.29)	2.81 (0.23)	9.99 (1.24)	14.83 (2.3) <sup>a</sup>	11.30 (3.24)	9.67 (1.34)	5.26 (0.15)	5.12 (0.24)	5.56 (0.18)	5.53 (0.32)
10	3.02 (0.27)	3.05 (0.33)	2.85 (0.32)	3.07 (0.41)	10.94 (1.9)	10.83 (0.66)	11.60 (0.89)	12.10 (1.28)	6.18 (0.52)	6.08 (0.32) <sup>b</sup>	6.82 (0.19)	6.61 (0.27)
15	3.32 (0.12)	10.06 (0.32) <sup>a</sup>	3.49 (0.34)	3.78 (0.35)	15.97 (1.02)	14.67 (0.99)	17.36 (1.35)	16.31 (3.49)	7.61 (0.74)	6.86 (0.64) <sup>b</sup>	7.79 (0.11)	9.06 (0.32)
20	5.08 (0.53)	4.29 (0.35)	4.02 (0.39) <sup>b</sup>	4.27 (0.42)	15.27 (1.34)	16.71 (1.39)	20.23 (3.42)	21.89 (6.81) <sup>a</sup>	8.30 (0.66)	7.51 (0.71) <sup>b</sup>	10.01 (0.36)	10.42 (0.41) <sup>a</sup>

**Tabla 7: Resultados a plazo medio [5]**

NNs models	DJIA				NASDAQ				STI			
	M1	M2	M3	M4	M1	M2	M3	M4	M1	M2	M3	M4
5	17.64 (1.71)	12.07 (2.01) <sup>a</sup>	13.24 (1.89)	12.65 (1.4)	29.05 (5.3)	22.84 (6.72) <sup>a</sup>	34.20 (4.55) <sup>b</sup>	36.21 (9.71) <sup>b</sup>	19.78 (3.21)	16.53 (1.02) <sup>a</sup>	22.22 (4.12)	16.98 (2.45)
10	16.72 (2.31)	15.80 (2.53)	17.20 (1.94)	20.69 (2.03)	47.64 (4.78)	48.73 (2.13)	54.29 (3.12)	43.70 (8.84)	25.93 (7.23)	26.54 (4.45)	44.16 (3.78) <sup>b</sup>	64.62 (1.11) <sup>b</sup>
15	26.03 (2.22)	17.12 (2.98) <sup>a</sup>	19.86 (3.04)	26.57 (1.2)	44.38 (4.5)	43.17 (5.67)	54.33 (7.13)	62.08 (1.38) <sup>b</sup>	75.08 (10.1)	39.48 (9.31) <sup>a</sup>	51.27 (7.23)	45.46 (3.21)
20	50.60 (0.98)	16.05 (3.4) <sup>a</sup>	15.28 (3.2)	30.02 (6.4)	88.29 (2.33)	60.85 (4.57) <sup>a</sup>	90.48 (7.8)	61.44 (9.1) <sup>a</sup>	27.94 (11.3)	17.80 (4.5) <sup>a</sup>	56.81 (7.89) <sup>b</sup>	59.09 (9.34) <sup>b</sup>

**Tabla 8: Resultados a largo plazo [5]**

### 3.3 Pronosticadores utilizando levenberg-marquardt

Shahrokh Asadi, Esmaeil HadavandiFarhad Mehmanpazir, Mohammad Masoud Nakhostin[12]. Proponen un modelo inteligente híbrido para predicción de acciones. Es una combinación de modelos de pre procesamiento de datos, algoritmos genéticos y algoritmo levenberg-marquardt para entrenar una red neuronal feed-forward.

Los pesos iniciales se entrenan por medio del algoritmo de levenberg-marquardt usando y utilizando algoritmos genéticos. Los modelos de pre procesamiento utilizados son transformación de datos y selección en las variables de entrada para mejorar la veracidad del modelo. El modelo propuesto es capas de predecir las fluctuaciones en la bolsa y entrega buen rendimiento en cuanto a la fiabilidad de la predicción.

A continuación se presentan resultados del modelo propuesto en comparación con otros modelos, todos ellos analizados en diferentes índices bursátiles.

Stock name	Method	MAPE (%)	Improvement (%)
Taiwan Stock Exchange index (TSE)	Hybrid of fuzzy clustering and TSK fuzzy system [21]	1.3	60
	TSK fuzzy system tuned by Simulated annealing [11]	2.4	78
	ANN trained with back-propagation (BPNN)	0.78	34
	Pre-processing Evolutionary Neural Networks (PENN)	0.67	23
	Pre-processing Evolutionary Neural Networks back propagation (PEBPNN)	0.52	1
	<b>PELMNN (Proposed model)</b>	<b>0.51</b>	–
Tehran Stock Exchange Prices Index (TEPIX)	Hybrid of fuzzy clustering and TSK fuzzy system [21]	2.4	78
	ANN trained with back-propagation (BPNN)	0.97	47
	Pre-processing Evolutionary Neural Networks (PENN)	0.64	20
	PEBPNN	0.61	18
	<b>PELMNN (Proposed model)</b>	<b>0.50</b>	–
	Index of top 50 Companies	Hybrid of fuzzy clustering and TSK fuzzy system [21]	1.85
ANN trained with back-propagation (BPNN)		1.4	45
Pre-processing Evolutionary Neural Networks (PENN)		1.12	32
Pre-processing Evolutionary Neural Networks back propagation (PEBPNN)		0.83	8
<b>PELMNN (Proposed model)</b>		<b>0.76</b>	–
Industry index		Hybrid of fuzzy clustering and TSK fuzzy system [21]	2.02
	ANN trained with back-propagation (BPNN)	1.73	47
	Pre-processing Evolutionary Neural Networks (PENN)	1.3	30
	Pre-processing Evolutionary Neural Networks back propagation (PEBPNN)	0.98	7
	<b>PELMNN (Proposed model)</b>	<b>0.89</b>	–
	Index of Financial Group	Hybrid of fuzzy clustering and TSK fuzzy system [21]	1.03
ANN trained with back-propagation (BPNN)		0.94	29
Pre-processing Evolutionary Neural Networks (PENN)		0.79	16
Pre-processing Evolutionary Neural Networks back propagation (PEBPNN)		0.69	4
<b>PELMNN (Proposed model)</b>		<b>0.66</b>	–
Dow Jones Industrial Average Index Series		ARIMA	10.23
	ANN(LM)	3.9	93
	TAEF[23]	1.13	–
	ANN trained with back-propagation (BPNN)	3.5	93
	Pre-processing Evolutionary Neural Networks (PENN)	2.4	82
	Pre-processing Evolutionary Neural Networks back propagation (PEBPNN)	2	40
	<b>PELMNN (Proposed model)</b>	<b>1.4</b>	–
Nasdaq Index Series	ARIMA	0.57	77
	ANN(LM)	0.27	51
	TAEF[23]	0.16	18
	ANN trained with back-propagation (BPNN)	0.3	56
	Pre-processing Evolutionary Neural Networks (PENN)	0.2	35
	Pre-processing Evolutionary Neural Networks back propagation (PEBPNN)	0.15	13
	<b>PELMNN (Proposed model)</b>	<b>0.13</b>	–

Tabla 9: Comparación de resultados de diferentes métodos [12]

Se utilizo un modelo de red neuronal de multicapas con un algoritmo de aprendizaje de levenber-marquardt[9]. Para pronosticar por un año o mas el caudal de un rio, para de esta forma poder almacenarla de ser necesario, ya sea para cultivos o cualquier uso que se requiera. Se almacena tomando en cuenta la necesidad de esta y mantener exactamente lo necesario para mantener un abastecimiento de agua continuo, en el caso de una siembre por ejemplo.

23 modelos de redes neuronales multicapa feed-forward fueron diseñados y entrenados utilizando el algoritmo de back-propagation de levenberg-marquardt, los mejores resultados fueron los siguientes.

	Testing		Average MSE	Average $r$	RMSE
	MSE	$r$			
<i>Model 14</i>					
$K_d/MAR$	0.6986	0.9576	0.8352	0.9578	0.9139
$K_i/MAR$	0.9717	0.9597			
<i>Model 16</i>					
$K_d/MAR$	2.1667	0.9055	2.4987	0.9033	1.5807
$K_i/MAR$	2.8307	0.901			

**Tabla 10: Mejores resultados de pronostico RNA LM [9]**

En el estudio de Martin T. Hagan and Mohammad B. Menhaj[13]. El algoritmo levenberg-marquadt para mínimos cuadrados no lineales, es incorporado en el algoritmo de back-propagation, para el entrenamiento de una red neuronal feed-forward. El algoritmo es probado en varios problemas de funciones de aproximación, y es comparado con el algoritmo de gradiente conjugada y el algoritmo de tasa variable de aprendizaje. Aquí se comprueba que el algoritmo levenberg-marquardt, es mucho mas eficiente que los otros para una red neuronal que no contenga muchos pesos. Pero el requerimiento computacional es mucho mayor por parte del algoritmo, pero esto es compensado por su aumento de eficiencia. Esto se hace mas importante cuando una mayor precisión es requerida.

También se comprobó que el algoritmo de levenberg-marquardt converge cuando los otros algoritmos fallaron en esto.

	VLBP	CGBP	MBP
Sine Wave	$8.42 \times 10^7$	$1.75 \times 10^7$	$1.89 \times 10^6$
Square Wave	$2.28 \times 10^9$	$1.49 \times 10^8$	$3.48 \times 10^7$
2-D Sinc	$2.94 \times 10^9$	$7.67 \times 10^8$	$1.07 \times 10^8$
4-D Test	—	$7.71 \times 10^9$	$1.97 \times 10^9$

**Tabla 11: numero de intentos para converger [13]**

## 4. Redes neuronales artificiales

A continuación se describirá una red neuronal la topología de estas, en que se basan y de que forma funcionan, el siguiente punto se dividirá en descripción de una red neuronal, luego una descripción de la función de activación en este caso será sigmoideal y en la descripción del algoritmo LM, PSO y GSA.

### 4.1 Descripción de red neuronal artificial

Los científicos han estudiado las capacidades humanas cerebrales, siendo ésta la base para la creación de nuevas máquinas por ello la inteligencia computacional se ha preocupado por imitar algunos de estos comportamientos de tipo biológico lo cual llevó a que se desarrollaran técnicas tales como las redes neuronales, algoritmos genéticos, y la lógica difusa entre otros, que también han sido adaptados a dispositivos electrónicos.

El cerebro humano está formado por unos cien mil millones de neuronas. Cada una de ellas consta de un cuerpo celular del cual surgen 2 tipos de ramificaciones: el axón (Fibra principal) y las dendritas (varias ramas fibrosas). Cada señal de entrada es captada por las dendritas y luego integradas y procesadas en su cuerpo celular para ser emitidas por el axón. Entre este terminal y el siguiente conjunto de dendritas se produce la sinapsis (transmisión de la excitación).

Análogamente cada elemento procesador (neurona) de la red neuronal artificial recibe parámetros de entrada (dendritas) los cuales son procesados por una función interna (en su soma o cuerpo celular) para generar una única salida para luego ser enviada hacia los demás elementos de la red (a través del axón). Las neuronas se agrupan en capas, las cuales están compuestas por múltiples neuronas procesadoras, cada una con comportamiento similar, constituyendo varias capas una red neuronal.

Las redes neuronales artificiales tienen un esquema de computación distribuida, que esta compuesto por unidades de proceso (nodos) con conexiones entre ellas ya sea todas entre si de una capa a otra o bajo algún parámetro indicado previamente ya sea comunicarse con neuronas intercaladas de la siguiente capa o comunicarse con neuronas de la misma capa, todo esto sucede en las capas interiores o ocultas, debido a que siempre se debe llegar a una salida.

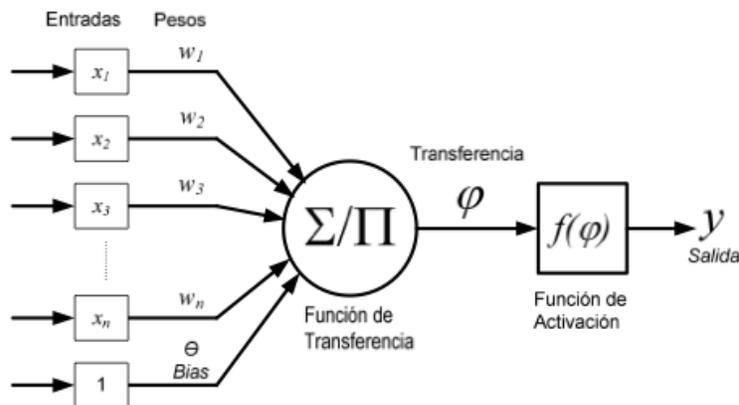


Ilustración 1: Red Neuronal Artificial

## 4.2 Redes neuronales de pronóstico

Una red neuronal puede ser descrita como un modelo de regresión no lineal cuya estructura se inspira en el funcionamiento del sistema nervioso. En términos generales, una red consiste en un gran número de unidades simples de proceso, denominadas neuronas, que actúan en paralelo y están conectadas mediante vínculos ponderados[7].

En este estudio se pronosticará la dirección que tomara una acción en el IPSA, esto se ha comprobado que no sigue un patrón lineal. Las redes neuronales son no lineales lo cual nos permitirá pronosticar el comportamiento de este índice.

A demás, las redes neuronales son capaces de generalizar, es decir, con la fase de entrenamiento la red neuronal puede extrapolar los datos analizados y de esta forma dar un resultado futuro, esto es ya que se utiliza la regla del perceptron para el cálculo de los pesos.

El Perceptron fue propuesto por Rosenblat (Rosenblat, 1959) en los años 50, la regla de aprendizaje 'Perceptron' es un método con procedimientos iterativos que ajustan los pesos. Un mismo aprendizaje se presenta a la red y para cada peso un nuevo valor es calculado agregando una corrección al valor anterior. Esta regla de aprendizaje Perceptron es usada para identificar una función discriminante correcta para un número de muestras.

Pero no solo en las predicciones financieras las redes neuronales se desempeñan de buena manera, se han conseguido muy buenos rendimientos en la predicción de la demanda en las industrias, de hecho los resultados apoyan la utilización de las redes neuronales artificiales como técnicas confiables de pronóstico y demuestran su factibilidad de instauración dentro de sus estrategias de negocios.

## 4.3 Función de activación sigmoideal

Entre las unidades o neuronas que forman una red neuronal artificial existe un conjunto de conexiones que las unen. Cada unidad transmite señales a aquellas que están conectadas a su salida. La función de activación transforma la entrada neta que la unidad presenta como resultado de estar conectada con otras unidades que le suministran información.

Se suele distinguir entre funciones lineales, en las que la salida es proporcional a la entrada; funciones de umbral, en las cuales la salida es un valor discreto (típicamente binario 0/1) que depende de si la estimulación total supera o no un determinado valor de umbral; y funciones no lineales, no proporcionales a la entrada.

Casi todos los avances recientes en conexionismo se atribuyen a arquitecturas multicapa que utilizan funciones de activación no lineales como una función de umbral, una gaussiana ó en la mayoría de los casos una función sigmoideal.

La función de activación en una red back-propagation debe cumplir varias cosas:

- Debe ser continua
- Debe ser diferenciable (y a ser posible, esta derivada debe ser fácil de calcular)
- Debe ser monótonica no decreciente.

La función de activación sigmoideal se trata de una función continua no lineal con bastante plausibilidad fisiológica. La función sigmoideal posee un rango  $[0,1]$ . Esto, aplicado a

las unidades de proceso de una red neuronal artificial significa que, sea cual sea la entrada, la salida estará comprendida entre 0 y 1.

Su ecuación es la siguiente:

$$f_1(x) = \frac{1}{1 + \exp(-x)}$$

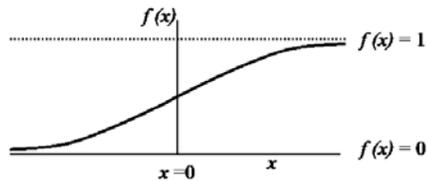
**Ecuación 1: Ecuación función sigmoideal**

A demás se puede ver que si derivada con respecto a x:

$$\frac{d}{dx} f_1(x) = f_1(x) \cdot [1 - f_1(x)]$$

**Ecuación 2: Derivada de función sigmoideal**

Ahora veremos el grafico de la función sigmoideal.



**Ilustración 2: Grafica de función sigmoideal**

## 4.4 Algoritmo Levenberg-Marquardt

El algoritmo LM (levenberg-marquardt) es el algoritmo de optimización mas usado. Supera al método gradiente descendente simple y a otros métodos conjugados de gradiente en una gran variedad de problemas[14].

El algoritmo LM es un algoritmo de optimización que provee una solución numérica al problema de minimizar una función, generalmente, no lineal dentro de un espacio de parámetros de la función. Dichos problemas de minimización aparecen, especialmente, al ajustar mínimos cuadrados lineales y no lineales.

El LM interpola entre el algoritmo de gauss-newton (GN) y un descenso de gradiente. LM es mas robusto que el GN, ya que se comporta como un descenso de gradiente lejos de la solución y como un GN cerca de ella.

El secreto del LM es alterar la diagonal de la matriz cuadrada producto de jacobianos en la ecuaciones normales de GN.

La ecuación del algoritmo de gauss-newton es la siguiente:

$$\Delta \underline{x} = [J^T(\underline{x})J(\underline{x})]^{-1} J^T(\underline{x})\underline{e}(\underline{x}).$$

**Ecuación 3: Ecuación del algoritmo de gauss-newton**

La ecuación del algoritmo de levenberg-marquardt es:

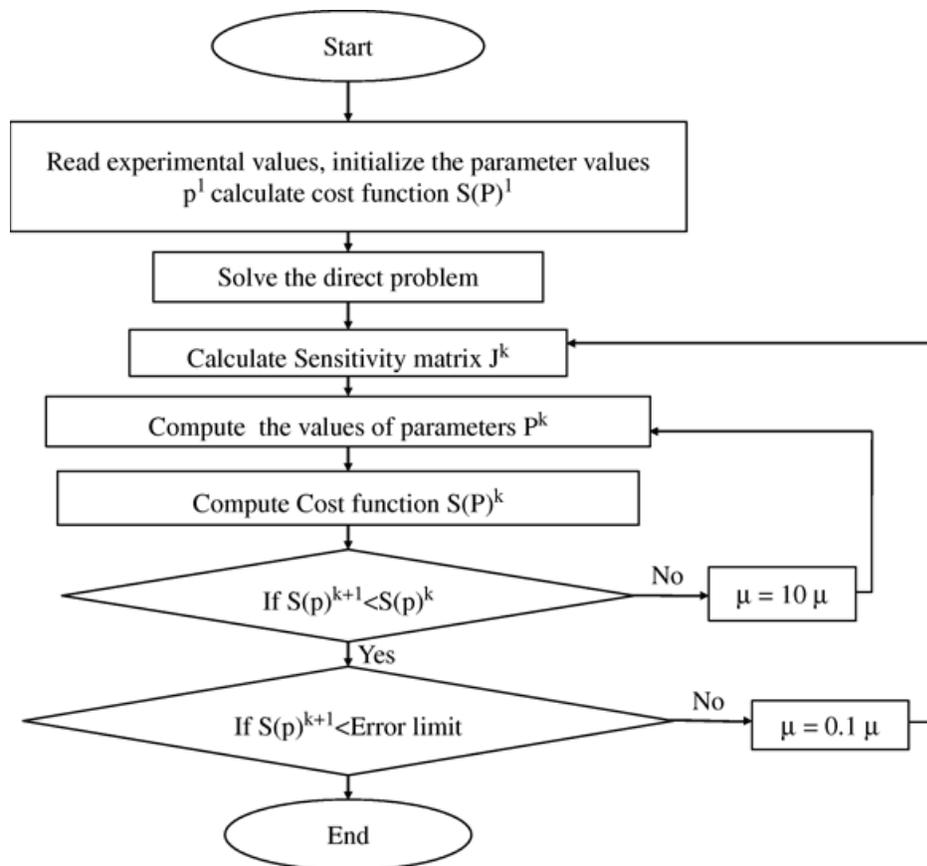
$$\Delta \underline{x} = [J^T(\underline{x})J(\underline{x}) + \mu I]^{-1} J^T(\underline{x})\underline{e}(\underline{x}).$$

**Ecuación 4: Ecuación algoritmo levenberg-marquardt**

El parámetro  $\mu$  es multiplicado por un factor  $\beta$  cuando se da un resultado de incremento y cuando el resultado se reduce el parámetro  $\mu$  es dividido por  $\beta$ . Cuando  $\mu$  es alto el algoritmo se vuelve mas descendente de gradiente, cuando  $\mu$  es pequeño el algoritmo se convierte en algoritmo gauss-newton. El algoritmo levenberg-marquardt puede ser considerado una modificación al intervalo de confianza de gauss-newton [13][14].

Este algoritmo presenta un inconveniente, si la dimensión es muy alta es inservible, ya que el producto de  $J^T(x)*J(x)$  es imposible de costear.

A continuación un esquema del funcionamiento del algoritmo LM:



**Ilustración 3: Algoritmo LM**

## 5. Métodos de pronóstico a largo plazo.

Existen diferentes métodos para que una red neuronal pueda hacer un pronóstico a largo plazo, con este a largo plazo nos referimos a un plazo mayor al plazo en que se miden los datos de entrada, en este caso, se pronosticará hasta 5 días en el futuro el precio de las acciones seleccionadas, se centrará este estudio en dos métodos, método directo y método indirecto.

### 5.1 Método directo

El método directo se basa en crear un modelo de red neuronal para cada día de pronóstico que se quiera medir, es decir, si quiero medir un día hacia el futuro se tiene una red, si se quiere medir 2 días hacia el futuro se tiene otra red, y así sucesivamente, este modelo se puede generalizar por medio de la siguiente ecuación.

$$y(n + k) = f(x, w)$$

**Ecuación 5: Método Directo**

Donde  $y$  es el día que se busca pronosticar, por lo tanto,  $n$  es el día actual y  $k$  es la cantidad de días al futuro, y donde  $f$  es el modelo neuronal que entrega el resultado pronosticado,  $x$  es el conjunto de datos de entrada y  $w$  es el conjunto de pesos de la red.

### 5.2 Método indirecto

El método indirecto a diferencia del método directo puede pronosticar más de un día hacia el futuro utilizando un solo modelo neuronal, se hace un pronóstico hacia un día en el futuro y luego ese resultado se vuelve a ingresar a la red, para pronosticar el siguiente día.

Este modelo tiene una complejidad menor ya que se utilizan menos modelos neuronales que el método directo, pero lleva un error mayor, ya que, se pronostica un resultado que tiene un cierto error, y luego se utiliza para pronosticar el siguiente día. Por lo tanto, el segundo día ya tendría error por su pronóstico y el del día anterior, esto hace que según el modelo, se pueda hacer un pronóstico de un día futuro solamente con días pronosticados, lo que puede hacer que el error sea excesivo.

## 6. Métricas de medición de modelos.

Estas métricas son utilizadas frecuentemente para la evaluación de modelos y comparación entre ellos. Por lo tanto, nuestro modelo será evaluado con estas mismas métricas para evaluar su desempeño. Y son las siguientes:

- Raíz del error cuadrático medio (RMSE)
- Error absoluto medio ponderado (MAPE)
- Error absoluto medio (MAE)
- Coeficiente de determinación ( $R^2$ )
- Validación cruzada generalizada (GCV)

RMSE (Root Mean Square Error o Raíz del Error Cuadrático Medio) realiza una diferencia entre los valores estimados y los valores reales, estas diferencias se elevan al cuadrado y se calcula el promedio de todas ellas. Como lo dice su nombre a este promedio se le debe calcular su raíz cuadrada. RMSE mide la magnitud de error. Su ecuación es la siguiente:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$
$$RMSE = \sqrt{MSE}$$

**Ecuación 6: Ecuación RMSE**

Donde  $y_i$  es el valor real,  $\hat{y}_i$  es el valor estimado, N es el tamaño de la muestra y MSE es el error cuadrático medio.

MAPE (Mean Absolute Percentage Error o Error Medio Absoluto Ponderado) permite medir la precisión en porcentaje que busca evaluar el rendimiento de modelos de pronóstico, su ecuación es la siguiente:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

**Ecuación 7: Ecuación MAPE**

Donde N es el tamaño de la muestra  $y_i$  es el valor real e  $\hat{y}_i$  es el valor estimado, multiplicando este resultado por cien, entrega el porcentaje de error.

MAE (Mean Absolute Error o Error Absoluto medio) entrega como resulta que tan cercano es la predicción hecha al resultado real, se parte haciendo una diferencia entre el valor obtenido y el valor real en valor absoluto y luego se le calcula el promedio. Su ecuación es:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

**Ecuación 8: Ecuación MAE**

Donde  $y_i$  es el valor real e  $\hat{y}_i$  es el valor estimado y N es el tamaño de la muestra.

El MAE en conjunto con el RMSE se utilizan para determinar la variación del error en el conjunto de mediciones, cabe notar que el RMSE siempre será mayor o igual al MAE (por su naturaleza cuadrática), por lo que a mayor diferencia entre MAE y RMSE mayor varianza entre los errores individuales de la muestra. Se espera que los resultados de MAE y RMSE sean cercanos a 0.

$R^2$  (Coeficiente de determinación) para esta métrica se espera un valor cercano a 1, indica que tan ajustados son los resultados obtenidos a la línea de regresión de los resultados reales. Si el resultado es 1 los datos se ajustan perfectamente. Su ecuación es:

$$R^2 = 1 - \frac{MSE_p}{MSE_M}$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2}$$

**Ecuación 9: Ecuación coeficiente de determinación**

Donde  $MSE_p$  es el error cuadrático medio de los valores estimados y  $MSE_M$  es el error cuadrático medio de la muestra.

GCV (Generalized Cross-Validation o validación cruzada generalizada) es una medida para evaluar el *trade-off* entre precisión y complejidad del modelo, se calcula de la siguiente manera:

$$GCV = \frac{MAPE}{(1 - (K/N))^2}$$

**Ecuación 10: Ecuación GCV**

Donde N es el tamaño de la muestra y K es el número de parámetros del modelo.

## 7. Resultados

Se analizaron tres acciones perteneciente al IPSA, con el fin de pronosticar un día hacia en el futuro y llegar hasta 5 días de pronóstico del precio que tomaran las acciones, en esta ocasión las acciones seleccionadas fueron de LAN, COPEC y SANTANDER.

Todas las acciones fueron comparadas con la misma configuración de la red neuronal con algoritmo de entrenamiento LM, la cual fue: 10 run, 1000 iteraciones,  $\mu = 0.001$ , que se multiplica o divide por 10 según corresponda y se probó de 1 hasta 10 nodos ocultos, lo cual tomó alrededor de 6 minutos para cada uno de los casos.

Se tomaron 2496 datos del precio de cierre de las acciones, estos corresponden desde 15 de diciembre de 2003 hasta 13 de diciembre del 2013, aproximadamente 10 años de datos, se utilizaron 7 datos de entrada para pronosticar el día siguiente.

El 80% de estos datos se utilizó para el entrenamiento de la red, es decir, 1997 datos y los otros 497 datos correspondientes al 20% restante se utilizaron para la prueba de la red.

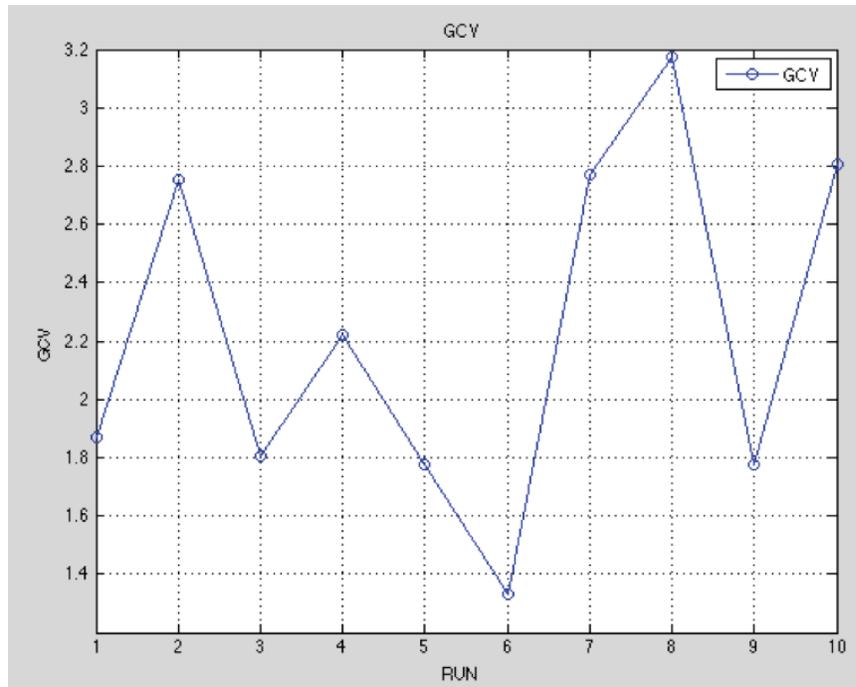
Se analizaron 4 gráficos correspondientes a la respuesta que entrega la red neuronal, estos son gráfico de correlación, gráfico de dispersión, gráfico de GCV y gráfico de valor estimado V/S valor real. Además de analizar las métricas mencionadas anteriormente, se mostrara el promedio de MAPE,  $R^2$  y GCV por cada nodo oculto y se mostraran todos los gráficos y métricas del mejor resultado obtenido.

### 7.1 Resultados LAN

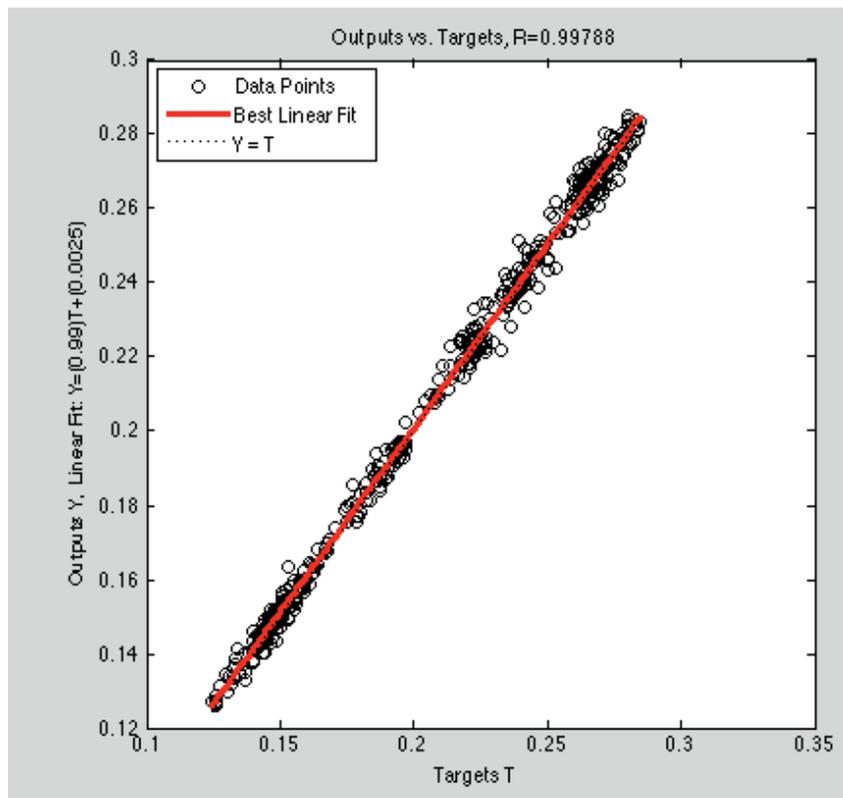
#### Mejor Resultado:

Cantidad nodos ocultos: 2	RUN: 6
$R^2$ : 0.995770	MAPE: 1.226614
RMSE: 0.003328	MAE: 0.002505
Porcentaje Acierto Dirección: 53.31%	Acierto dirección: 265

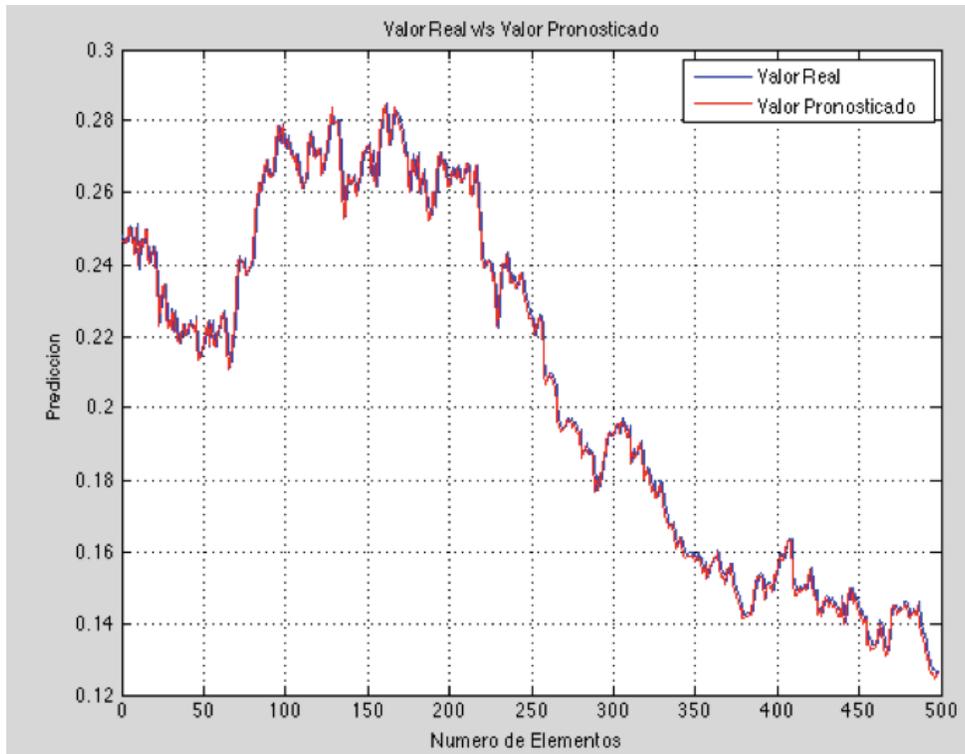
Tabla 12: Mejor resultado LAN primer día



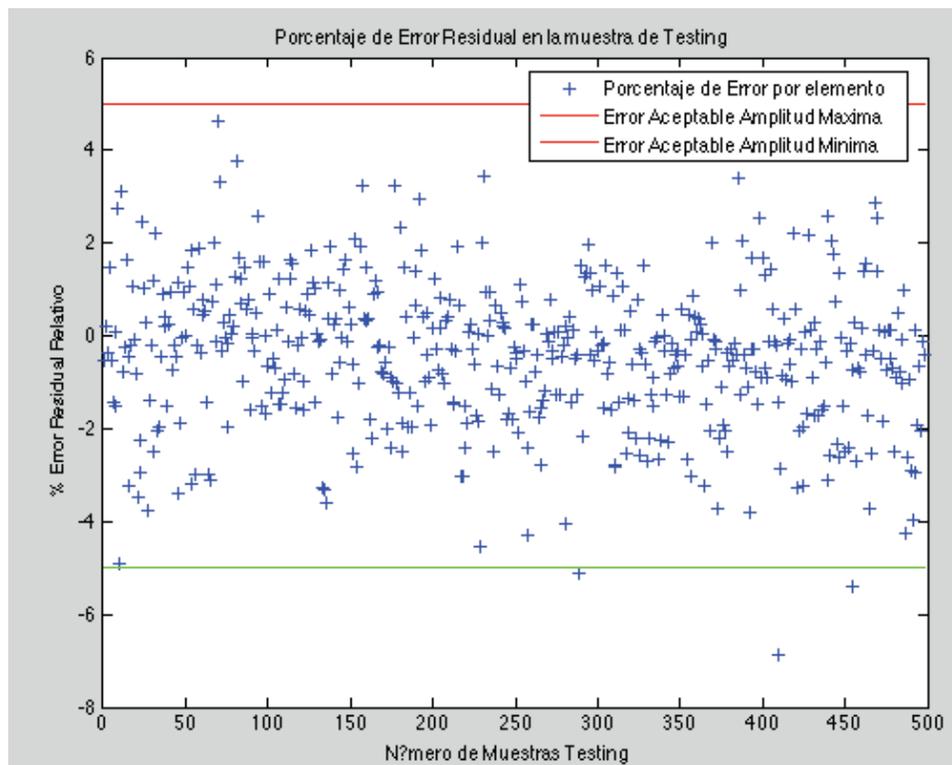
**Ilustración 4: Gráfico GCV LAN, primer día**



**Ilustración 5: Gráfico de correlación LAN, Primer día**



**Ilustración 6: Gráfico valor real v/s valor estimado LAN, Primer día**

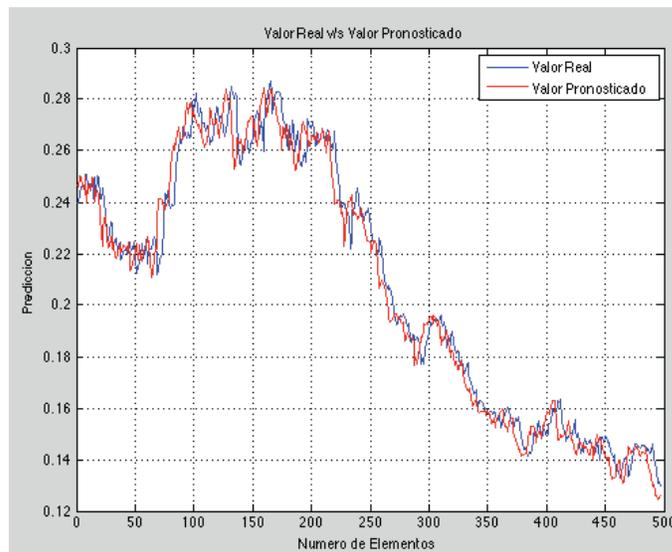


**Ilustración 7: Gráfico dispersión LAN, Primer día**

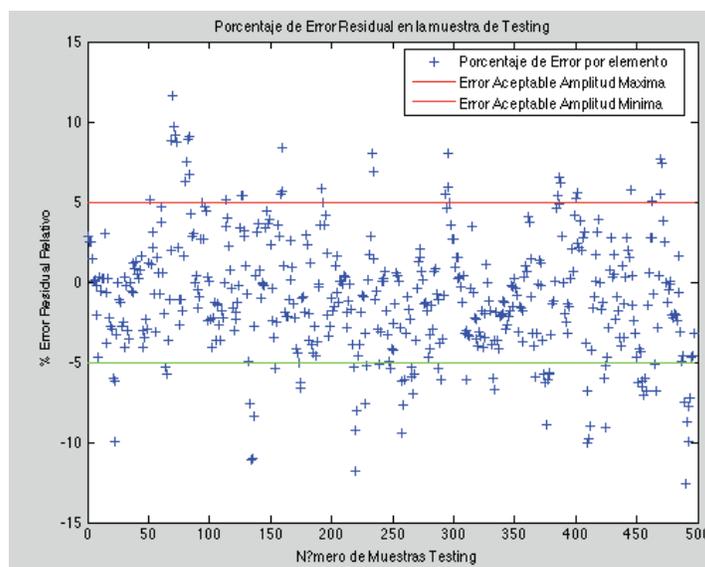
Para el Pronostico del quinto día, se pudo observar que el MAPE aumento y  $R^2$  disminuyo, esto es porque al pronosticar el quinto día el error es mayor que para el anterior.

Cantidad nodos ocultos: 4	RUN: 1
$R^2$ : 0.974684	MAPE: 3.010320
RMSE: 0.008069	MAE: 0.006125
Porcentaje Acierto Dirección: 49.49%	Acierto dirección: 246

**Tabla 13: Mejor resultado LAN quinto día**



**Ilustración 8: LAN valor real v/s Pronosticado, quinto día**



**Ilustración 9: LAN Grafico dispersión, quinto día**

## 7.2 Resultados LAN producción diciembre - junio

Aquí se muestran los resultados obtenidos para la producción del método directo, con los datos de junio 2014.

Cantidad nodos ocultos: 6	RUN: 2
$R^2$ : 0.137841	MAPE: 1.303444
RMSE: 0.013610	MAE: 0.012556
Porcentaje Acierto Dirección: 58.33%	Acierto rentabilidad: 71.75%

Tabla 14: Mejor resultado LAN método directo junio 2014

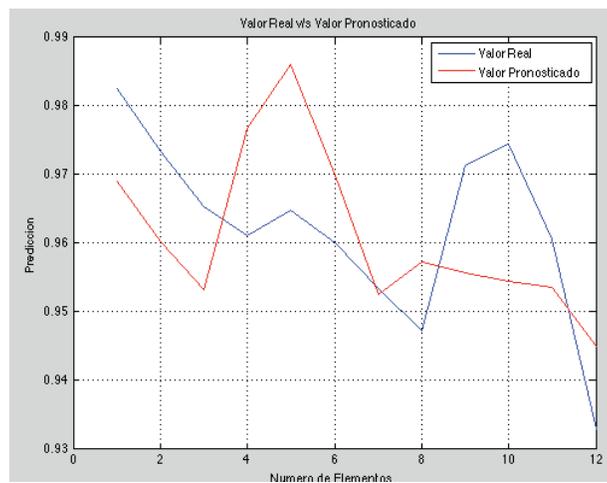


Ilustración 10: Gráfico estimado v/s valor real junio directo

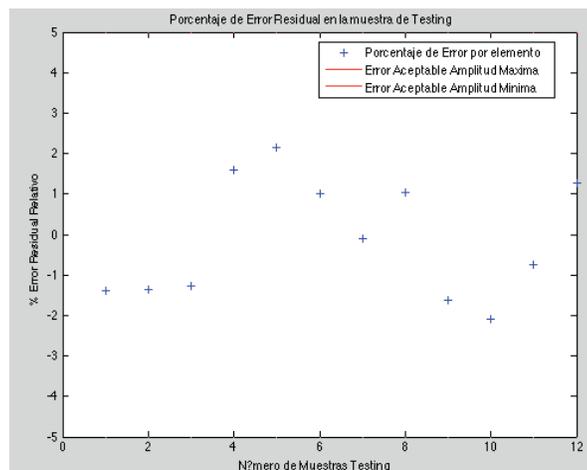
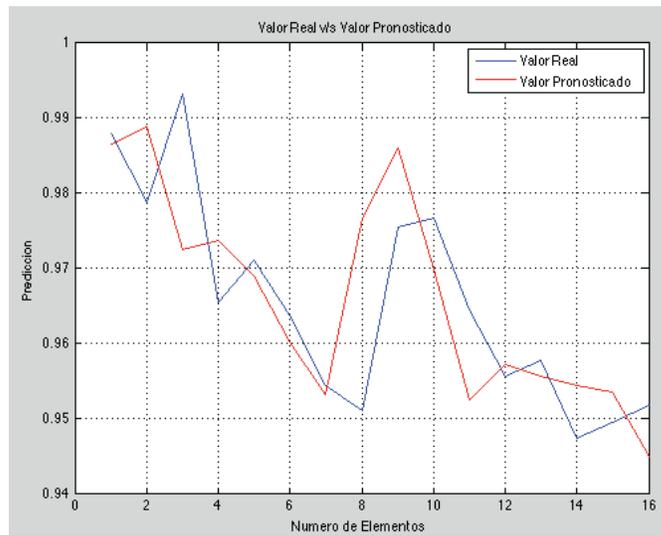


Ilustración 11: Gráfico de correlación LAN, Primer día

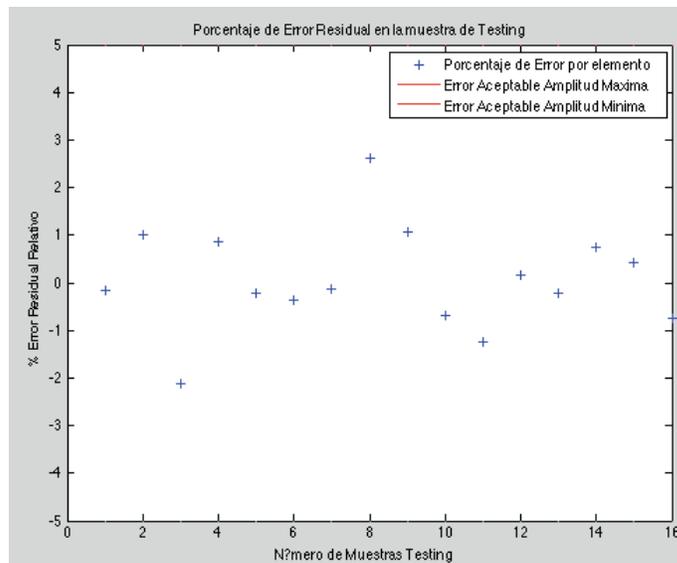
Aquí se muestran los resultados obtenidos para la producción del método indirecto, con los datos de junio 2014.

Cantidad nodos ocultos: 4	RUN: 1
$R^2$ : 0.506627	MAPE: 0.797176
RMSE: 0.010282	MAE: 0.007730
Porcentaje Acierto Dirección: 50%	Acierto Rentabilidad: 34.10%

**Tabla 15: Mejor resultado LAN método indirecto junio 2014**



**Ilustración 12: LAN valor real v/s Pronosticado, indirecto junio**

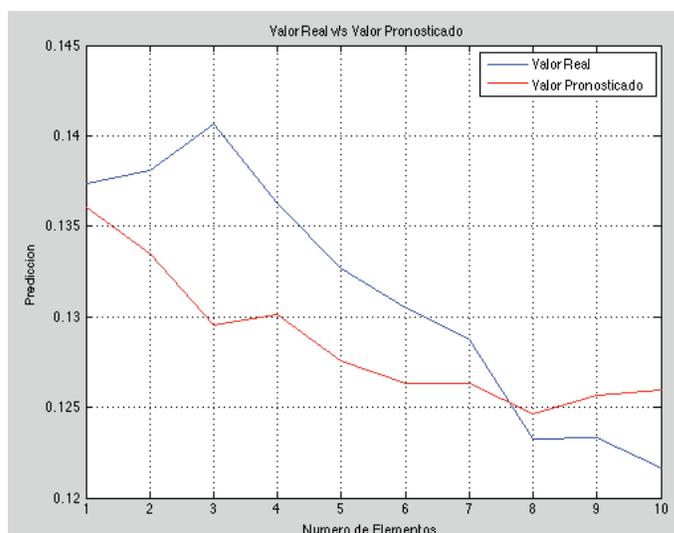


**Ilustración 13: LAN Grafico dispersión, indirecto junio**

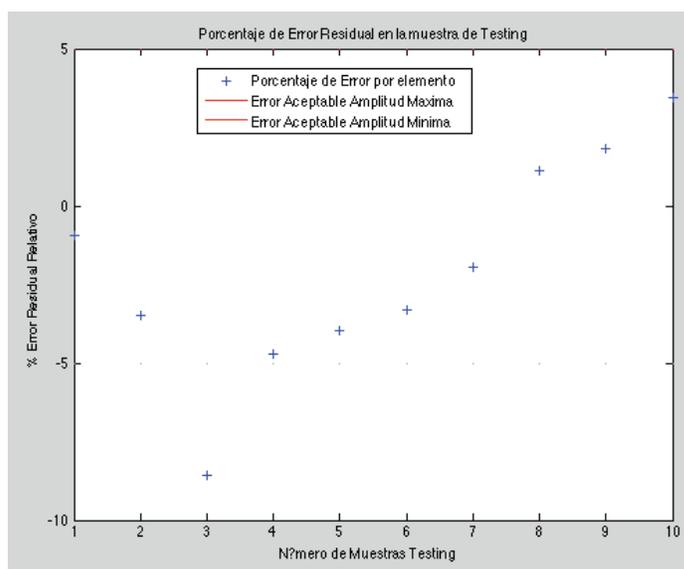
Aquí se muestran los resultados obtenidos para la producción del método directo, con los datos de diciembre 2013.

Cantidad nodos ocultos: 8	RUN: 4
$R^2$ : 0.619917	MAPE: 3.329949
RMSE: 0.005086	MAE: 0.004287
Porcentaje Acierto Dirección: 40%	Acierto dirección: 79.42%

**Tabla 16: Mejor resultado LAN directo diciembre 2013**



**Ilustración 14: LAN valor real v/s Pronosticado, diciembre 2013**

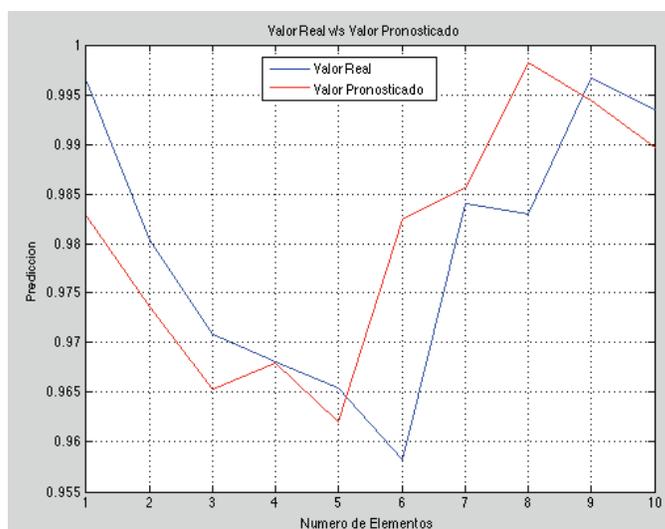


**Ilustración 15: LAN Grafico dispersión, diciembre 2013**

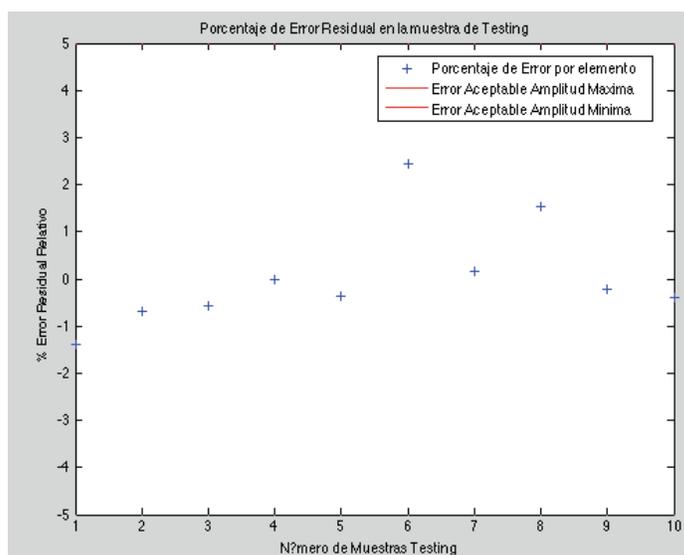
Aquí se muestran los resultados obtenidos para la producción del método indirecto, con los datos de diciembre 2013.

Cantidad nodos ocultos: 4	RUN: 1
$R^2$ : 0.409078	MAPE: 0.779086
RMSE: 0.010537	MAE: 0.007661
Porcentaje Acierto Dirección: 60%	Acierto Rentabilidad: 33.05%

**Tabla 17: Mejor resultado LAN indirecto diciembre 2013**



**Ilustración 16: LAN valor real v/s Pronosticado, indirecto diciembre 2013**

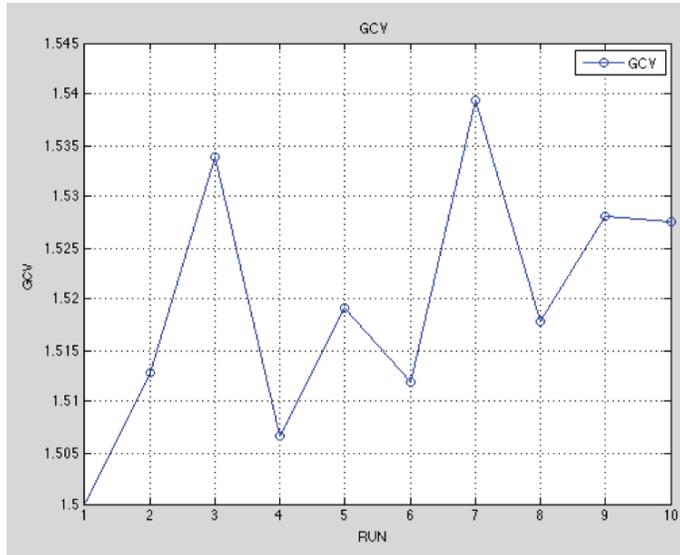


**Ilustración 17: LAN Grafico dispersión, indirecto diciembre 2013**

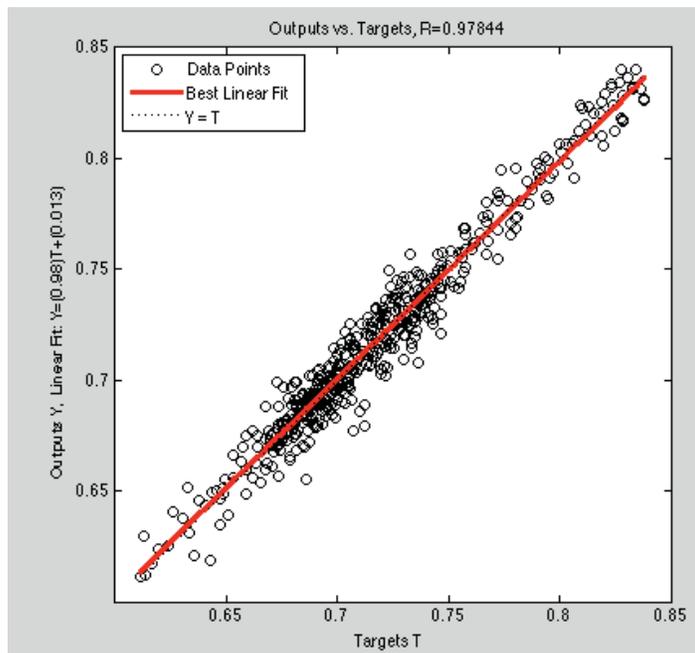
### 7.3 Resultados COPEC

Cantidad nodos ocultos: 6	RUN: 5
$R^2$ : 0.956087	MAPE: 1.019763
RMSE: 0.009319	MAE: 0.007294
Porcentaje Acierto Dirección: 53.72%	Acierto dirección: 267

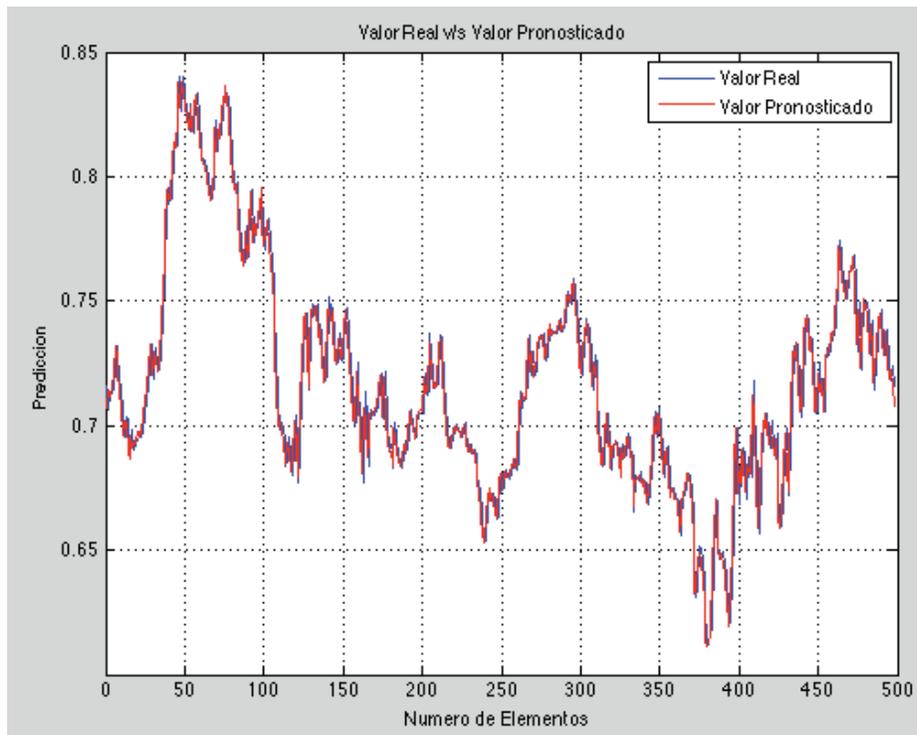
**Tabla 18: Mejor resultado COPEC, Primer día**



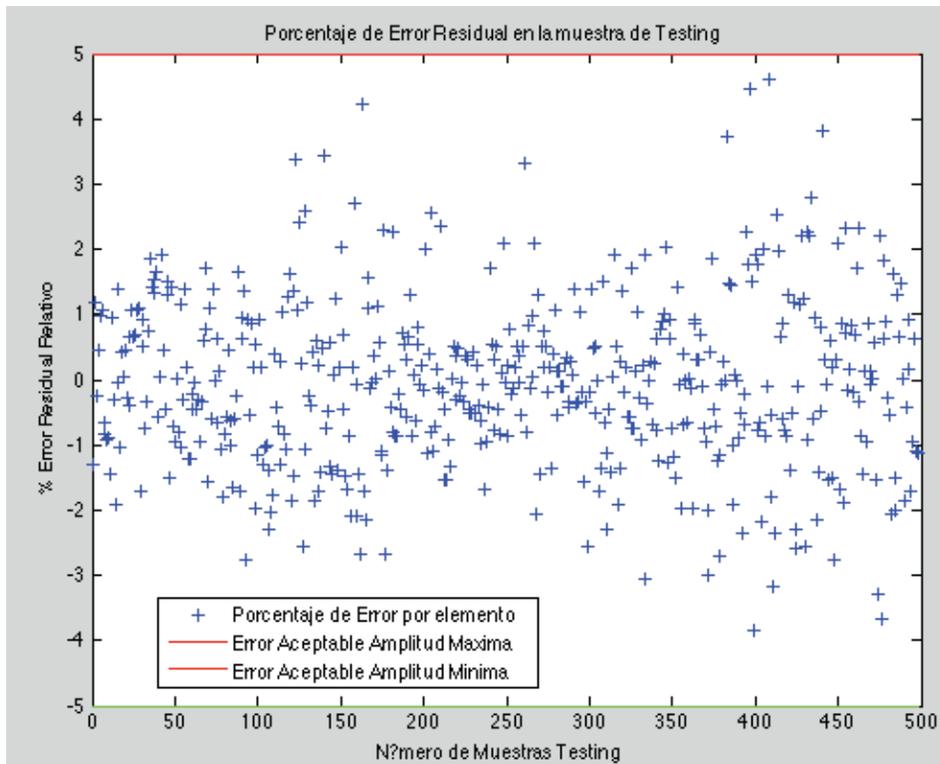
**Ilustración 18: Gráfico GCV COPEC, primer día**



**Ilustración 19: Gráfico de correlación COPEC, primer día**



**Ilustración 20: Gráfico valor real v/s pronosticado COPEC, primer día**

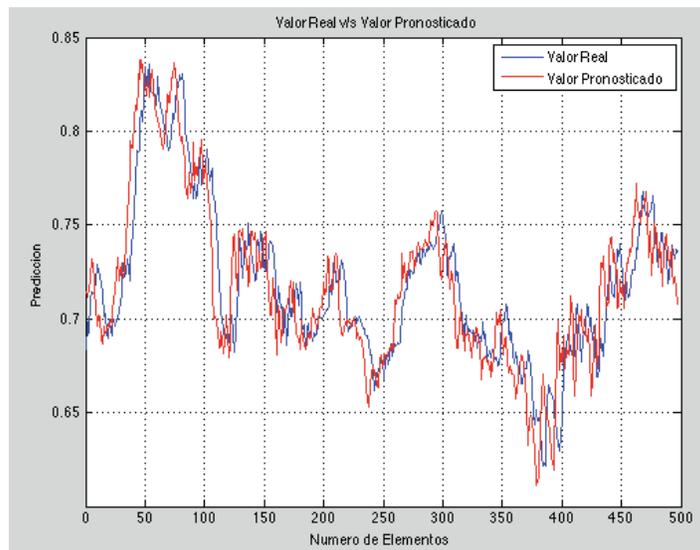


**Ilustración 21: Gráfico dispersión COPEC**

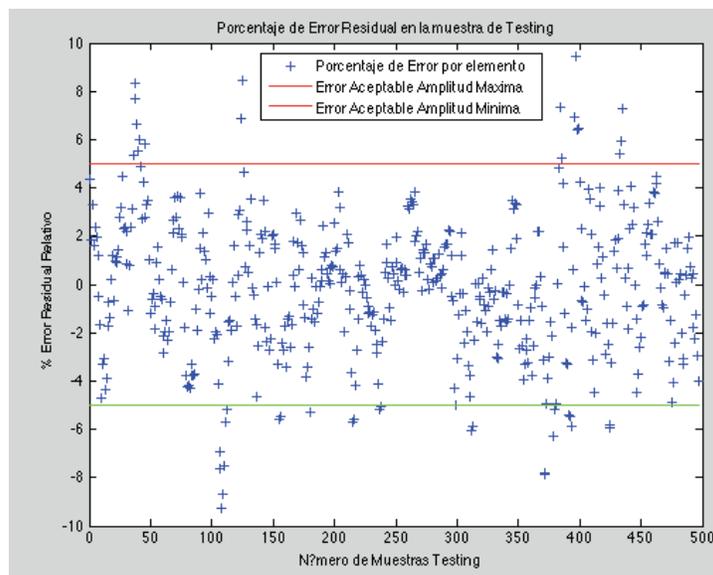
Para el Pronostico del quinto día, se pudo observar que el MAPE aumento y  $R^2$  disminuyo, esto es porque al pronosticar el quinto día el error es mayor que para el anterior.

Cantidad nodos ocultos: 3	RUN: 1
$R^2$ : 0.789949	MAPE: 2.215991
RMSE: 0.020504	MAE: 0.015858
Porcentaje Acierto Dirección: 53.31%	Acierto dirección: 265

**Tabla 19: Mejor resultado COPEC quinto día**



**Ilustración 22: COPEC valor real v/s Pronosticado, quinto día**



**Ilustración 23: COPEC Grafico dispersión, quinto día**

## 7.4 Resultados COPEC producción diciembre – junio

Aquí se muestran los resultados obtenidos para la producción del método directo, con los datos de junio 2014.

Cantidad nodos ocultos: 4	RUN: 10
$R^2$ : 0.052855	MAPE: 0.883552
RMSE: 0.009798	MAE: 0.008424
Porcentaje Acierto Dirección: 58.33%	Acierto rentabilidad: 83.33%

Tabla 20: Mejor resultado COPEC, directo junio 2014

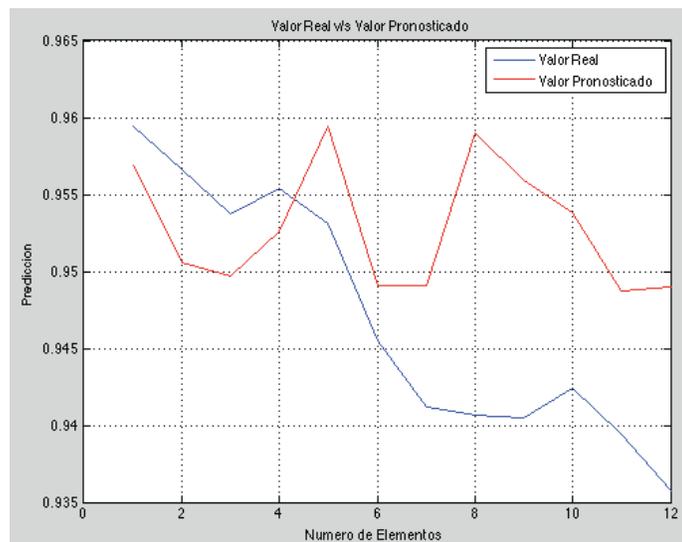


Ilustración 24: Gráfico GCV COPEC, directo junio

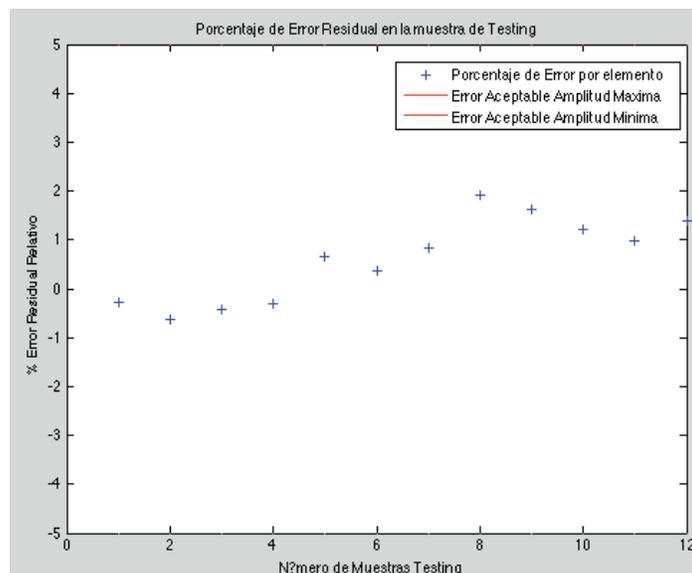
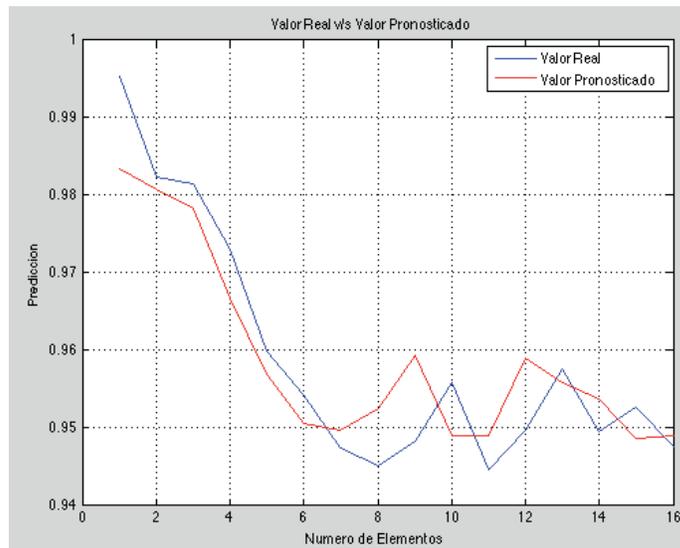


Ilustración 25: Gráfico de correlación COPEC, directo junio

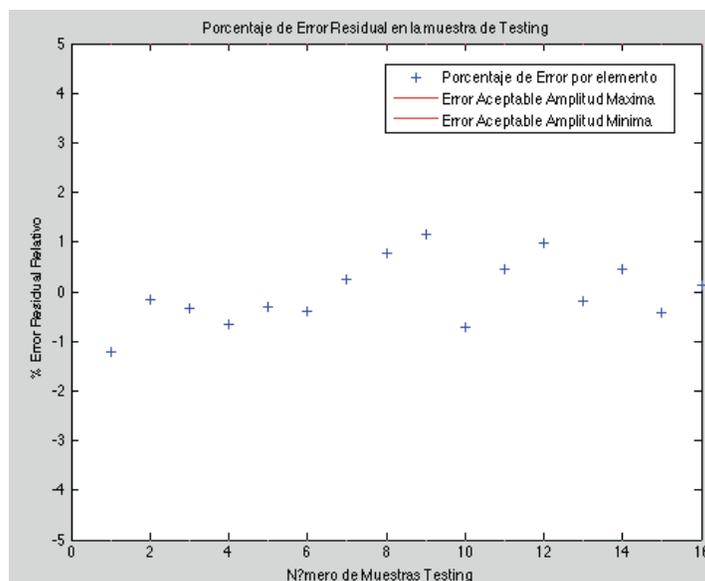
Aquí se muestran los resultados obtenidos para la producción del método indirecto, con los datos de junio 2014.

Cantidad nodos ocultos: 1	RUN: 1
$R^2$ : 0.859754	MAPE: 0.533587
RMSE: 0.006065	MAE: 0.005125
Porcentaje Acierto Dirección: 62.5%	Acierto rentabilidad: 89.53%

**Tabla 21: Mejor resultado COPEC indirecto junio 2014**



**Ilustración 26: COPEC valor real v/s Pronosticado, indirecto junio**

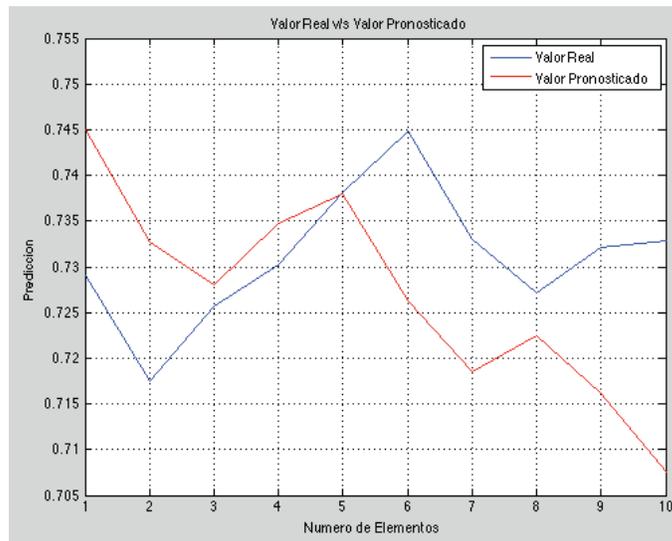


**Ilustración 27: COPEC Grafico dispersión, indirecto junio**

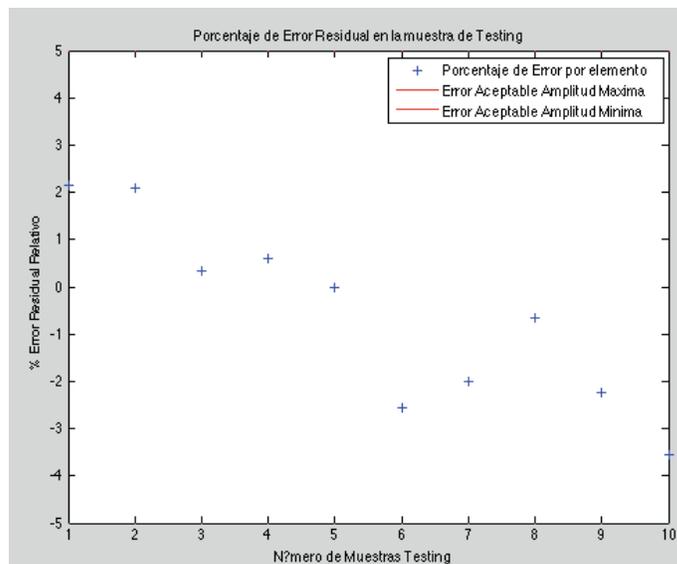
Aquí se muestran los resultados obtenidos para la producción del método directo, con los datos de diciembre 2013.

Cantidad nodos ocultos: 9	RUN: 8
$R^2$ : 0.020788	MAPE: 1.622644
RMSE: 0.014102	MAE: 0.011737
Porcentaje Acierto Dirección: 40%	Acierto rentabilidad: 28.64%

**Tabla 22: Mejor resultado COPEC directo diciembre 2013**



**Ilustración 28: COPEC valor real v/s Pronosticado, directo diciembre**

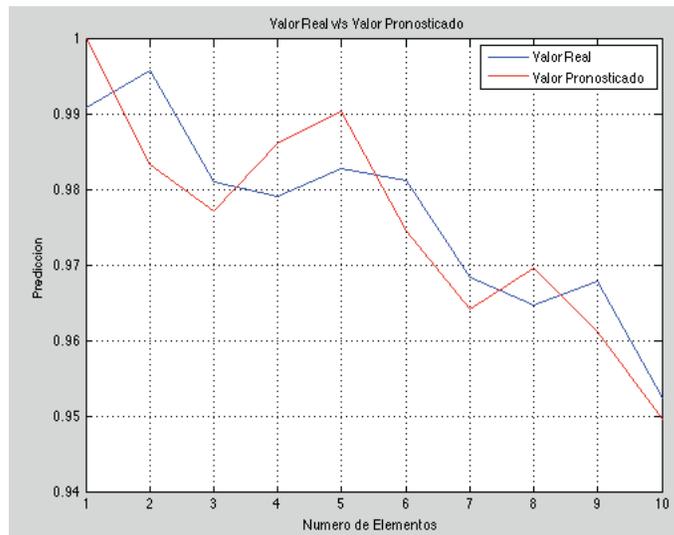


**Ilustración 29: COPEC Grafico dispersión, directo diciembre**

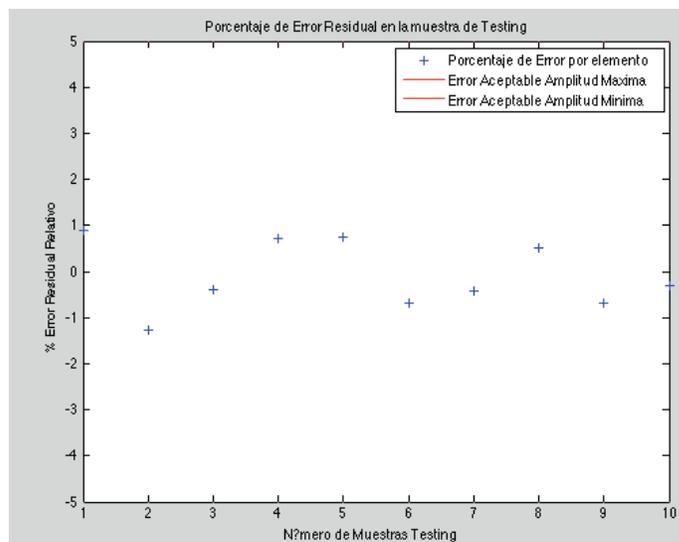
Aquí se muestran los resultados obtenidos para la producción del método indirecto, con los datos de diciembre 2013.

Cantidad nodos ocultos: 1	RUN: 1
$R^2$ : 0.759891	MAPE: 0.664930
RMSE: 0.007032	MAE: 0.006512
Porcentaje Acierto Dirección: 50%	Acierto rentabilidad: 88.12%

**Tabla 23: Mejor resultado COPEC indirecto diciembre 2013**



**Ilustración 30: COPEC valor real v/s Pronosticado, indirecto diciembre**



**Ilustración 31: COPEC Grafico dispersión, indirecto diciembre**

## 7.5 Resultados SANTANDER

### Mejor Resultado:

Cantidad nodos ocultos: 9	RUN: 7
$R^2$ : 0.981041	MAPE: 0.983349
RMSE: 0.009164	MAE: 0.006965
Porcentaje Acierto Dirección: 46.27 %	Acierto dirección: 230

Tabla 24: Mejor resultado Santander primer día

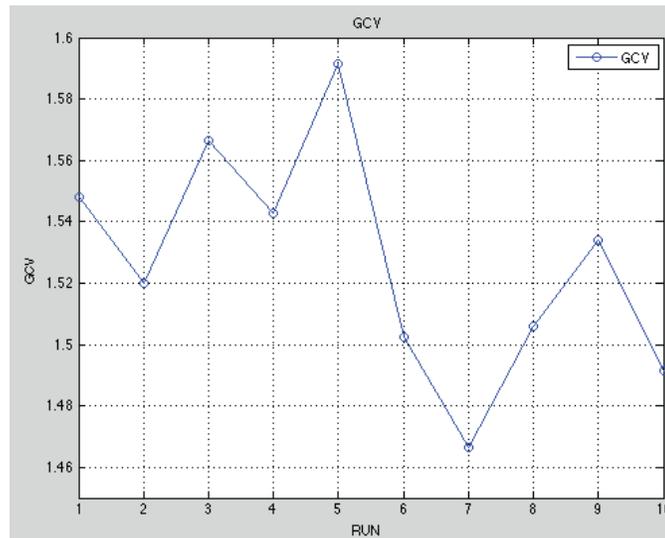


Ilustración 32: Gráfico GCV Santander, Primer día

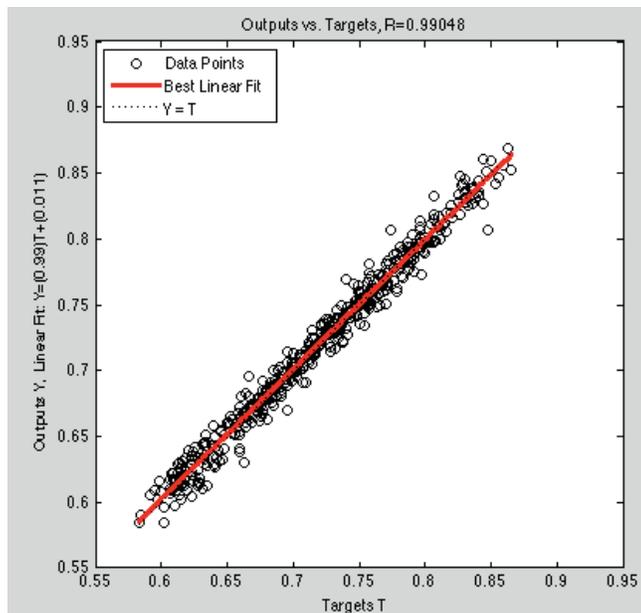
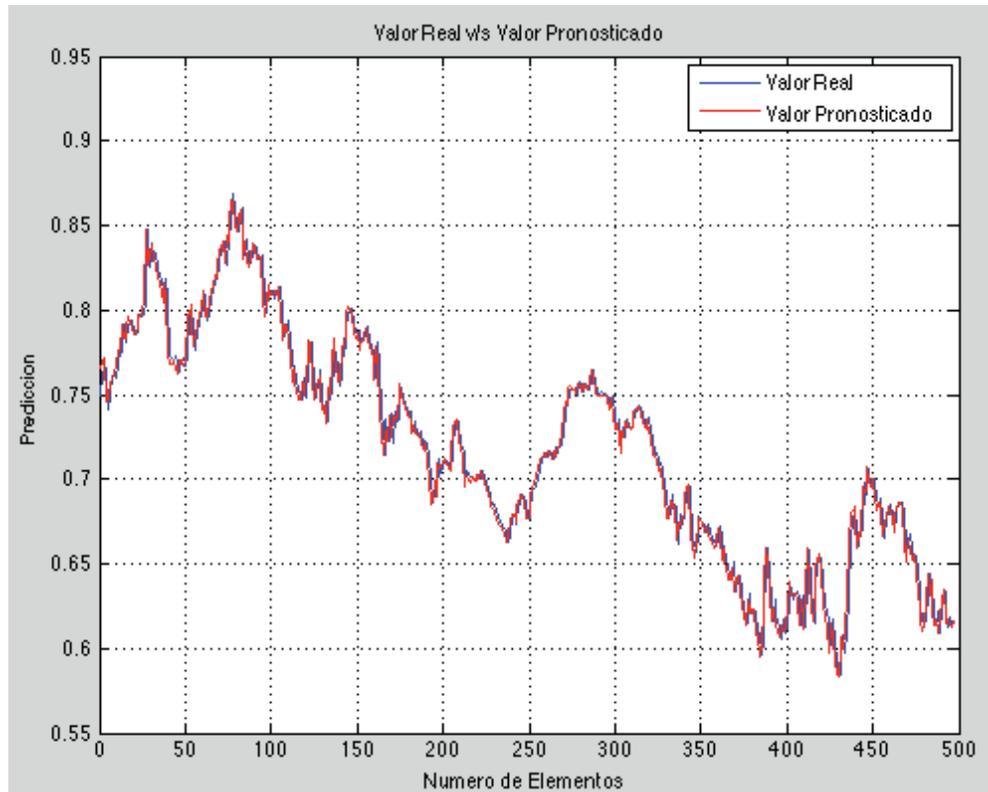
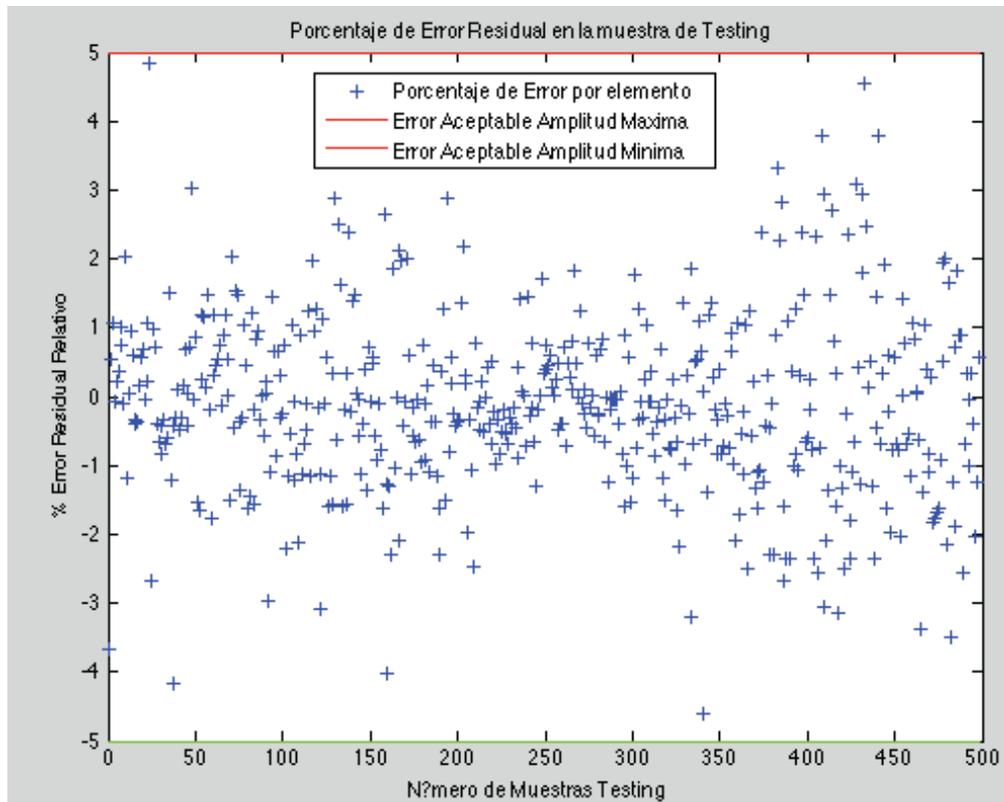


Ilustración 33: Gráfico de correlación Santander, Primer día



**Ilustración 34: Gráfico valor real v/s pronosticado Santander, Primer día**

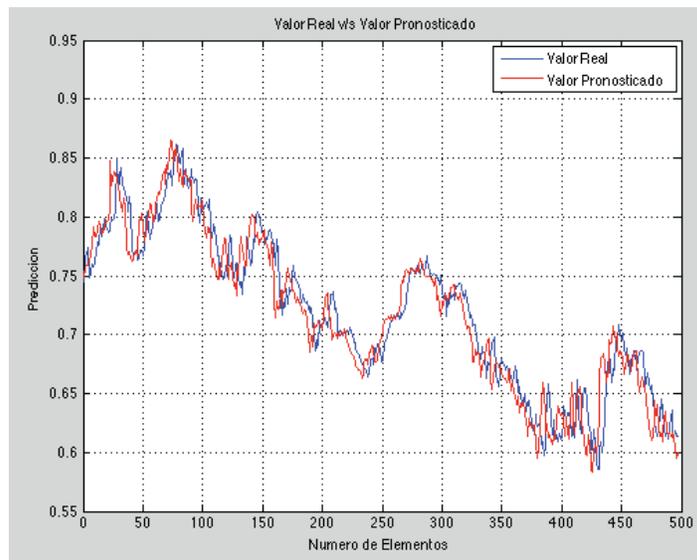


**Ilustración 35: Gráfico dispersión Santander, Primer día**

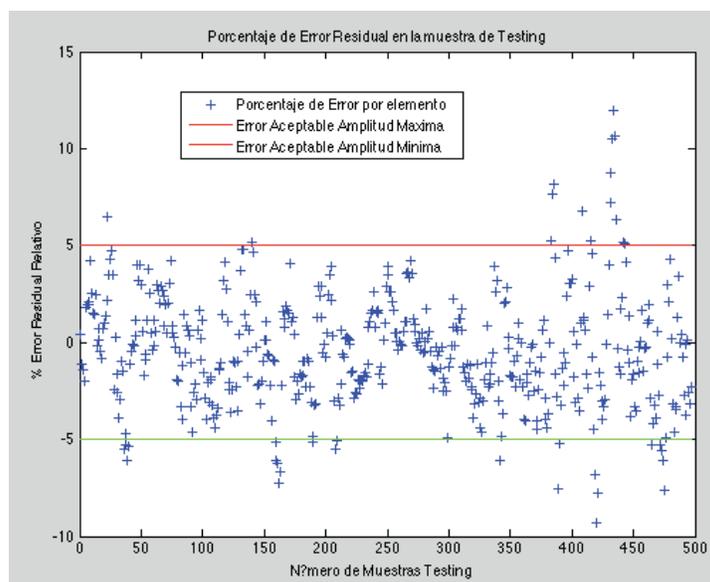
Para el Pronostico del quinto día, se pudo observar que el MAPE aumento y  $R^2$  disminuyo, esto es porque al pronosticar el quinto día el error es mayor que para el anterior.

Cantidad nodos ocultos: 5	RUN: 2
$R^2$ : 0.910442	MAPE: 2.249842
RMSE: 0.020274	MAE: 0.015906
Porcentaje Acierto Dirección: 48.08%	Acierto dirección: 239

**Tabla 25: Mejor resultado Santander quinto día**



**Ilustración 36: Santander valor real v/s Pronosticado, quinto día**



**Ilustración 37: Santander Grafico dispersión, quinto día**

## 7.6 SANTANDER producción junio - diciembre

Aquí se muestran los resultados obtenidos para la producción del método directo, con los datos de junio 2014.

Cantidad nodos ocultos: 5	RUN: 3
$R^2$ : 0.153820	MAPE: 2.148865
RMSE: 0.023227	MAE: 0.021181
Porcentaje Acierto Dirección: 25%	Acuerdo rentabilidad: 14.22%

Tabla 26: Mejor resultado Santander directo junio 2014

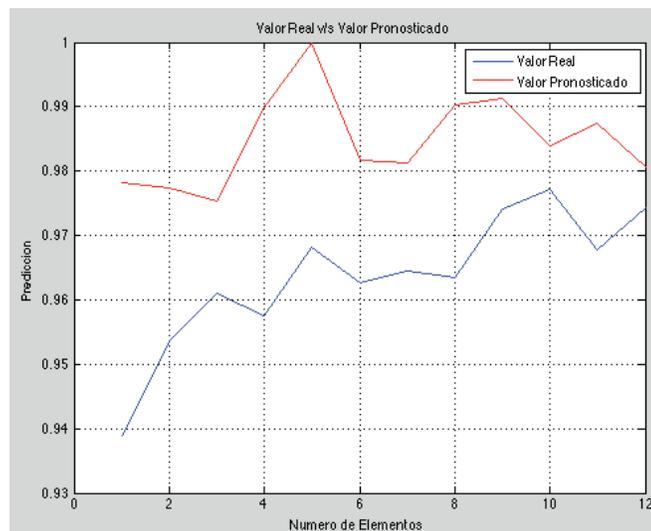


Ilustración 38: Gráfico GCV Santander, directo junio 2014

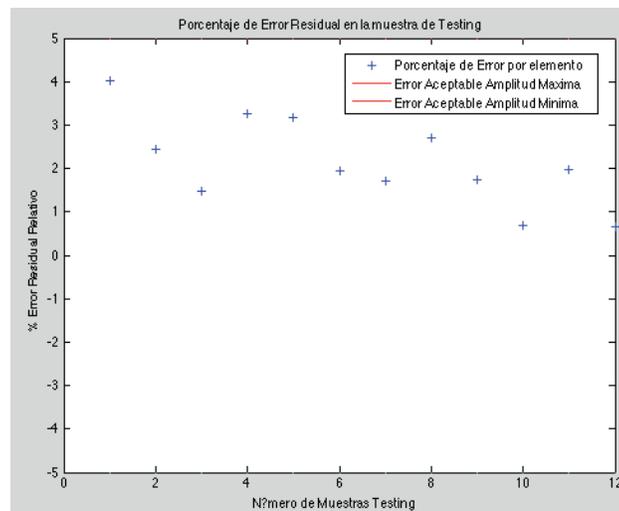
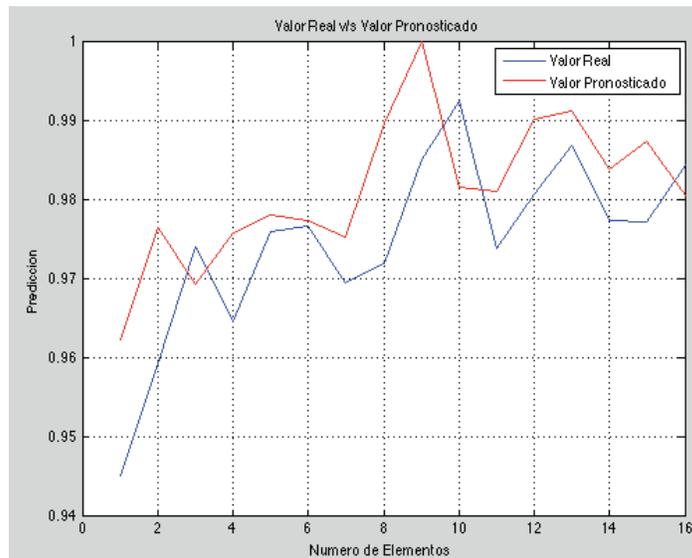


Ilustración 39: Gráfico de correlación Santander, directo junio 2014

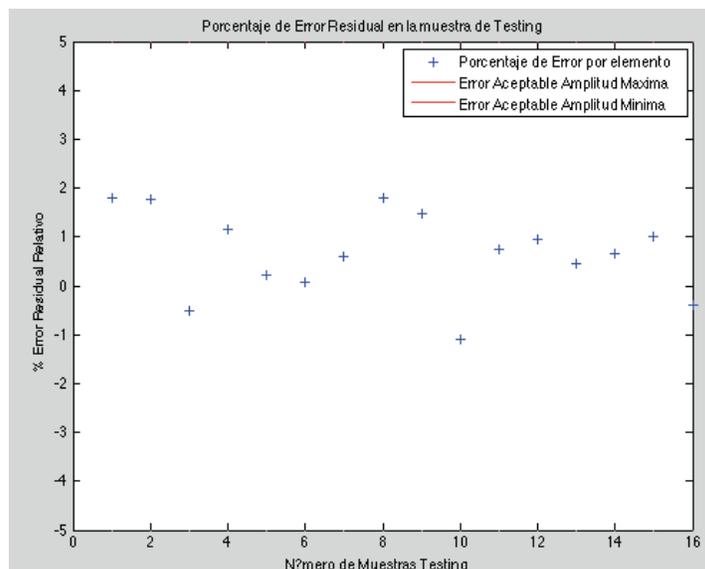
Aquí se muestran los resultados obtenidos para la producción del método indirecto, con los datos de junio 2014.

Cantidad nodos ocultos: 7	RUN: 1
$R^2$ : 0.472204	MAPE: 0.918400
RMSE: 0.010482	MAE: 0.009016
Porcentaje Acierto Dirección: 56.25%	Acierto rentabilidad: 81.36%

**Tabla 27: Mejor resultado Santander indirecto junio 2014**



**Ilustración 40: Santander valor real v/s Pronosticado, indirecto junio 2014**

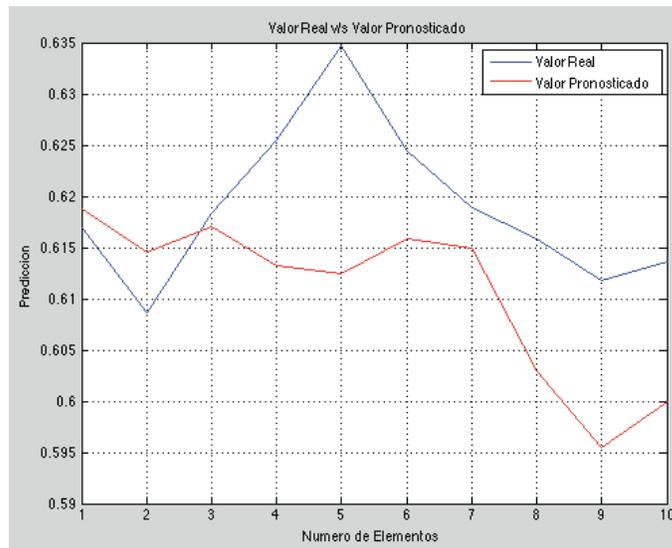


**Ilustración 41: Santander Grafico dispersión, indirecto junio 2014**

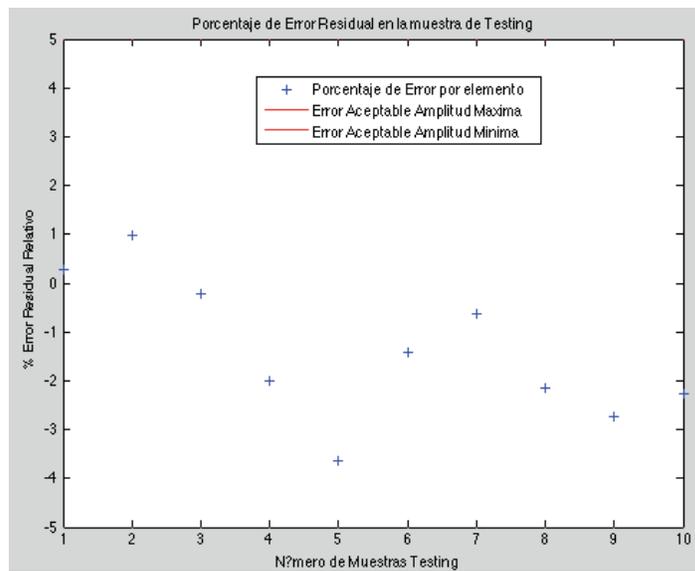
Aquí se muestran los resultados obtenidos para la producción del método directo, con los datos de diciembre 2013.

Cantidad nodos ocultos: 7	RUN: 8
$R^2$ : 0.135012	MAPE: 1.628998
RMSE: 0.011805	MAE: 0.009894
Porcentaje Acierto Dirección: 60%	Acierto rentabilidad: 14.20%

**Tabla 28: Mejor resultado Santander directo diciembre 2013**



**Ilustración 42: Santander valor real v/s Pronosticado, directo diciembre 2013**

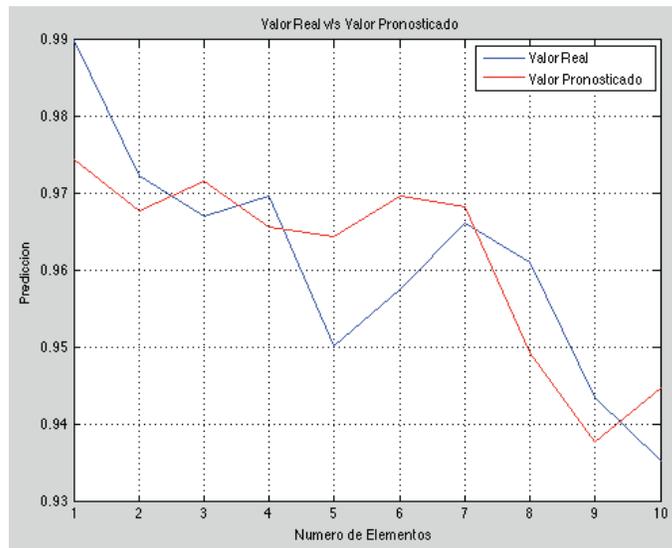


**Ilustración 43: Santander Grafico dispersión, directo diciembre 2013**

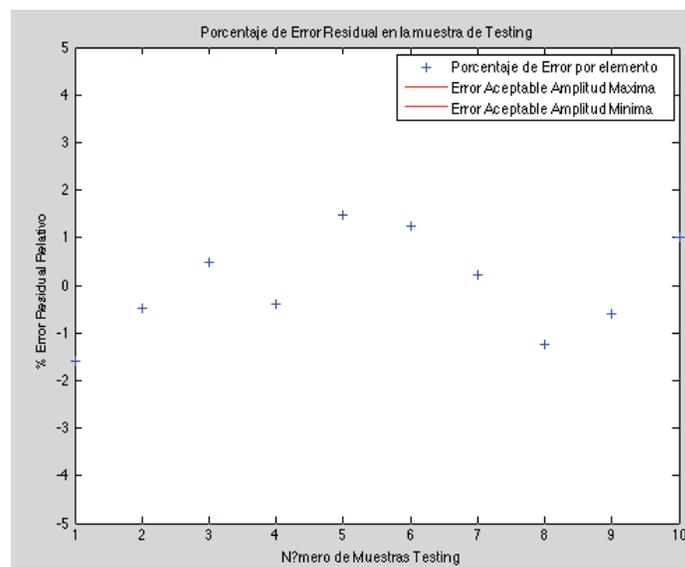
Aquí se muestran los resultados obtenidos para la producción del método indirecto, con los datos de diciembre 2013.

Cantidad nodos ocultos: 7	RUN: 1
$R^2$ : 0.585796	MAPE: 0.876905
RMSE: 0.009563	MAE: 0.008432
Porcentaje Acierto Dirección: 50%	Acierto rentabilidad: 18.11%

**Tabla 29: Mejor resultado Santander indirecto diciembre 2013**



**Ilustración 44: Santander valor real v/s Pronosticado, indirecto diciembre 2013**



**Ilustración 45: Santander Grafico dispersión, indirecto diciembre 2013**

## 8. Conclusión

Como se pudo observar durante todo el documento, los pronósticos utilizando redes neuronales son los que presentan los resultados más acertados para este tipo de problemas, como lo es el pronóstico del curso que tomara una acción en el IPSA.

Se pudo observar de varios autores que por medio de diferentes algoritmos de aprendizaje y diferentes formas de entrenar redes neuronales lograron buenos resultados, lo importante es que el factor en común, que es el uso de redes neuronales.

También se pudo observar en los estudios del algoritmo de levenberg-marquardt, que sirve para el pronóstico de diferentes problemas. A demás, en el estudio de pronóstico del precio que tomara una acción en el mercado bursátil, donde se utilizó redes neuronales y algoritmo levenber-marquart se comparó con otros métodos y esta combinación logró los mejores resultados[12].

Se analizaron 3 acciones del IPSA como se había planificado y todas dieron excelentes resultados para el pronóstico de primer día, LAN fue la mejor con  $R^2$ : 0.995770, MAPE: 1.226614, RMSE: 0.003328, MAE: 0.002505, le sigue SANTANDER con  $R^2$ : 0.981407, MAPE: 0.978355, RMSE: 0.009148, MAE: 0.006904, y finalmente COPEC con  $R^2$ : 0.957349, MAPE: 1.006983, RMSE: 0.009233, MAE: 0.00720.

Se pudo observar que con el método directo, cada vez que se aumentaba los días de pronóstico futuro disminuía el  $R^2$  y aumentaba el MAPE, el coeficiente de correlación incluso llego a ser de 78% en el peor de los casos para COPEC en el quinto día. Gracias a esto se pudo observar que el coeficiente de correlación no es un buen indicador de nuestro modelo, por lo tanto se dio paso a analizar la cantidad de veces que se acertaba en el pronóstico de la dirección de la curva.

Estos resultados fueron representativos del modelo, ya que se observó que el modelo como esta fluctúa en un acierto entre un 50 a 60%, si bien es poco el porcentaje de acierto, se espera calibrar la red una vez más para obtener mejores resultado o simplemente concluir que este modelo no es el más optimo para el pronóstico de acciones, los resultados individuales al quinto día de pronóstico y utilizando 10 muestras de testing fueron de 50% para LAN, 60% para COPEC y 50% para SANTANDER, con los 497 datos de testing y pronóstico al quinto día los resultados fueron 49.49% para LAN, 53.31% para COPEC y 48.08% para SANTANDER.

Para la parte de producción se observaron los 2 métodos directo e indirecto, el método directo acertó en 2 de las 6 veces para el pronóstico al quinto día, lo que corresponde a un 33% de acierto a la tendencia que tomara la curva, el método más exitoso fue el indirecto que tubo un 100% de acierto de pronóstico de la dirección de la curva con el pronóstico al quinto día, como fue nuestra meta propuesta desde un principio.

Como se esperaba, el algoritmo de levenberg-marquardt entregó resultados positivos en cuanto a la rentabilidad, indicó que en un sentido acertado si se va a rentabilizar o no, la diferencia fue en la rentabilidad real, alcanzó un porcentaje de acierto de un 14.63% en cuanto a la rentabilidad con respecto a la rentabilidad real de Santander, es decir, si se rentabilizaban 100 pesos en el período, el modelo sólo indicaba que se rentabilizarían 14.63 pesos, 65.36% con respecto a la rentabilidad de LAN y 16.52% con respecto a la rentabilidad de COPEC.

De acuerdo a los resultados obtenidos por nuestro modelo de red neuronal propuesto, se puede decir que no se recomienda el uso de método directo para el pronóstico de este caso particular, es decir, las 3 acciones seleccionadas del IPSA. Sin embargo, esto demostró que el mercado es bastante impredecible, ya que con el simple hecho de no tener los valores de los 4 días anteriores, el error es muy elevado incluso entregando un resultado erróneo de si subirá o bajará el valor de la acción dentro del mercado.

Con respecto a los resultados obtenidos por el método indirecto, se puede decir que se recomienda el uso de este método, ya que de las 6 pruebas hechas para los periodos de tiempo distintos, con 6 meses de diferencia entre ellos y utilizando el mismo entrenamiento, los resultados fueron de un 100% de acierto en cuanto a si el valor de la acción subirá o bajará dentro de los 5 días de pronóstico.

Para finalizar, podemos apreciar que el modelo propuesto es exitoso en cuanto al pronóstico del valor que tomarán las acciones del IPSA, se cumplieron los objetivos del estudio y se comprobó, que para nuestro caso el método que dio mejores resultados fue el método indirecto y que su uso es recomendable.

## 9. Referencias

- [1] Qing Cao, Karyl B. Leggio, Marc J. Schniederjans. (2005). “A comparison between Fama and French’s model and artificial neural networks in predicting the Chinese stock market”, *Computers & Operations Research* 32, 2499–2512.
- [2] Panayiotis C. Andreou, Chris Charalambous, Spiros H. Martzoukos. 2008. “Prisión and trading European options by combining artificial neural networks and parametric models with implied parameters”. *European Journal of Operational Research* 185, 1415–1433
- [3] David Enke, Suraphan Thawornwong. (2005). “The use of data mining and neural networks for forecasting stock market returns”, *Expert Systems with Applications* 29, 927–940
- [4] Thira Chavarnakul, David Enke. 2008. “Intelligent technical analysis based equivolume charting for stock trading using neural networks”, *Expert Systems with Applications* 34, 1004–1017
- [5] Xiaotian Zhu , Hong Wang, Li Xu , Huaizu Li. 2008. “Predicting stock index increments by neural networks: The role of trading volume under different horizons”. *Expert Systems with Applications*. 34, 3043–3054
- [6] A.J. Adeloje, A. De Munari. 2006. “Artificial neural network based generalized storage–yield–reliability models using the Levenberg–Marquardt algorithm”. *Journal of Hydrology* 362, 215–230
- [7] Cristian Foix, Richard Weber. 2007. “pronostico del precio del cobre mediante redes neuronales”. *Revista de ingeniería de sistemas*. 11, 63-86.
- [8] Pei-Chann Chang, Chen-Hao Liu, Jun-Lin Lin, Chin-Yuan Fan, Celeste S.P. Ng. 2009. “A neural network with a case based dynamic window for stock trading prediction”, *Expert Systems with Applications* 36, 6889–6898
- [9] A.J. Adeloje, A. De Munari. 2006. “Artificial neural network based generalized storage–yield–reliability models using the Levenberg–Marquardt algorithm”. *Journal of Hydrology* 362, 215–230
- [10] Gerencia de Planificación y Desarrollo. 2010. “Metodología de Selección y Cálculo de Índices Bursátiles”, *Bolsa Comercio Santiago*
- [11] Ou, Phichhang & Wang, Hengshan. 2009. “Prediction of Stock Market Index Movement by Ten Data Mining Techniques”, *Modern Applied Science*.
- [12] Shahrokh Asadi, Esmail HadavandiFarhad Mehmanpazir, Mohammad Masoud Nakhostin. 2012. “Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction”. *knowledge-Based Systems* 35, 245–258

- [13] Martin T. Hagan and Mohammad B. Menhaj. 1994. "Training Feedforward Networks with the Marquardt Algorithm". IEEE TRANSACTIONS ON NEURAL NETWORKS, V01, 5, NO 6.
- [14] Ananth Ranganathan. 2004. "The Levenberg-Marquardt Algorithm". 1, 1-5
- [15] SeyedAli Mirjalili, Siti Zaiton Mohd Hashim, Hossein Moradian Sardroudi, 2012, "Training feedforward neural networks using hybrid particle swarm optimization and gravitational search algorithm", Applied Mathematics and Computation 218, 11125–11137.
- [16] J. Kennedy, R.C. Eberhart, 1995, "Particle swarm optimization", Proceedings of IEEE International Conference on Neural Networks, vol. 4, 1942–1948.
- [17] Antonio C. Briza, Prospero C. Naval Jr., 2011, "Stock trading system based on the multi-objective particle swarm optimization of technical indicators on end-of-day market data", Applied Soft Computing, 11, 1191–1201.
- [18] M.R. Sierra, C.C. Coello, 2006, "Multi-objective particle swarm optimizers: a survey of the state-of-the-art", International Journal of Computational Intelligence Research, 23, 287–308.
- [19] E. Rashedi, S. Nezamabadi, S. Saryazdi, 2009, "GSA: a gravitational search algorithm", Information Sciences 179, 13, 2232–2248.
- [20] I. Newton, 1729, "In experimental philosophy particular propositions are inferred from the phenomena and afterwards rendered general by induction", 3rd ed.: Andrew Motte's English translation published, vol. 2.
- [21] S. Sinaie, 2010, "Solving shortest path problem using Gravitational Search Algorithm and Neural Networks", Universiti Teknologi Malaysia (UTM), Johor Bahru, Malaysia, M.Sc. Thesis.
- [22] Guoqiang Zhang, B. Eddy Patuwo, Michael Y. Hu, 1998, "Forecasting with artificial neural networks: the state of art", International journal of forecasting, 14, 35 – 62.
- [23] Hammerstrom, D., 1993. Neural networks at work, IEEE Spectrum, June, 26–32.
- [24] De Gooijer, J.G., Kumar, K., 1992. Some recent developments in non-linear time series modelling, testing, and forecasting. International Journal of Forecasting 8, 135–156.
- [25] Donaldson, R.G., Kamstra, M., 1996. Forecasting combining with neural networks. Journal of Forecasting 15, 49–61.
- [26] Hinton, G.E., 1992. How neural networks learn from experience, Scientific American, September, 145–151.
- [27] Refenes, A.N., 1995. Neural Networks in the Capital Markets. John Wiley, Chichester.
- [28] Srinivasan, D., Liew, A.C., Chang, C.S., 1994. A neural network short-term load forecaster. Electric Power Systems Research 28, 227–234.
- [29] Poli, I., Jones, R.D., 1994. A neural net model for prediction. Journal of American Statistical Association 89 (425), 117–121.

## **Anexos**

## A: Empresas que participan en el IPSA 2014

Nemo	Razón Social	Peso Relativo
AESGENER	AES GENER S.A.	1,79
AGUAS-A	AGUAS ANDINAS S.A., SERIE A	2,51
ANDINA-B	EMBOTELLADORA ANDINA S.A. SERIE B	1,30
ANTARCHILE	ANTARCHILE S.A.	2,13
BANMEDICA	BANMEDICA S.A.	0,80
BCI	BANCO DE CREDITO E INVERSIONES	3,42
BESALCO	BESALCO S.A.	0,29
BSANTANDER	BANCO SANTANDER-CHILE	5,13
CAP	CAP S.A.	2,17
CCU	COMPANIA CERVECERIAS UNIDAS S.A.	2,30
CENCOSUD	CENCOSUD S.A.	5,25
CFR	CFR PHARMACEUTICALS S.A.	0,65
CGE	COMPANIA GENERAL DE ELECTRICIDAD S.A.	0,94
CHILE	BANCO DE CHILE	3,42
CMPC	EMPRESAS CMPC S.A.	3,34
COLBUN	COLBUN S.A.	3,11
CONCHATORO	VINA CONCHA Y TORO S.A.	1,34
COPEC	EMPRESAS COPEC S.A.	9,16
CORPBANCA	CORPBANCA	3,07
CRUZBLANCA	CRUZ BLANCA SALUD S.A.	0,44
ECL	E.CL S.A.	0,88
EMBONOR-B	COCA-COLA EMBONOR S.A. SERIE "B"	0,35
ENDESA	EMPRESA NACIONAL DE ELECTRICIDAD S.A.	6,72
ENERSIS	ENERSIS S.A.	8,72
ENTEL	EMP. NACIONAL DE TELECOMUNICACIONES S.A.	1,85
FALABELLA	S.A.C.I. FALABELLA	5,41
FORUS	FORUS S.A.	0,53
IAM	INVERSIONES AGUAS METROPOLITANAS S.A.	1,02
ILC	INVERSIONES LA CONSTRUCCION S.A.	0,61
LAN	LATAM AIRLINES GROUP S.A.	8,52
PARAUCO	PARQUE ARAUCO S.A.	1,32
RIPLEY	RIPLEY CORP S.A.	0,85
SALFACORP	SALFACORP S.A.	0,35
SECURITY	GRUPO SECURITY S.A.	1,40
SK	SIGDO KOPPERS S.A.	0,59
SM-CHILE B	SOCIEDAD MATRIZ BANCO DE CHILE, SERIE B	1,97
SMSAAM	SOCIEDAD MATRIZ SAAM S.A.	0,70
SONDA	SONDA S.A.	1,52
SQM-B	SOC QUIMICA MINERA DE CHILE S.A. SERIE B	3,57
VAPORES	COMPANIA SUD AMERICANA DE VAPORES S.A.	0,57