



**UNIVERSIDAD DEL BÍO-BÍO
FACULTAD DE CIENCIAS EMPRESARIALES
DEPARTAMENTO DE GESTIÓN EMPRESARIAL**

**USO DE REDES NEURONALES ARTIFICIALES EN LA
PREDICCIÓN DE PRECIOS CONFORMADAS POR LAS ACCIONES
CON MAYOR PESO RELATIVO DE LOS INDICES SECTORIALES
BANCA, COMMODITIES, CONSUMO, INDUSTRIAL Y RETAIL DE
LA BOLSA DE COMERCIO DE SANTIAGO DE CHILE**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO COMERCIAL

AUTOR : OLIVA SILVA, LUIS ALFREDO

Profesor Guía: Dr. Cabas Monje Juan

Verano- Otoño 2014



UNIVERSIDAD DEL BÍO-BÍO
FACULTAD DE CIENCIAS EMPRESARIALES
ESCUELA INGENIERÍA COMERCIAL

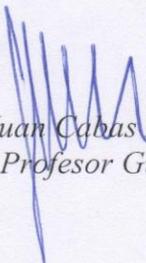
Chillán, Abril 17 de 2014.

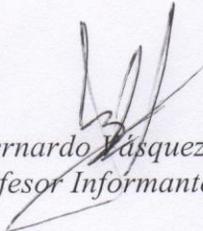
Informe: Memoria de Título

En relación a la evaluación de la Memoria para optar al Título de Ingeniero Comercial, denominada "USO DE REDES NEURONALES ARTIFICIALES EN LA PREDICCIÓN DE PRECIOS CONFORMADAS POR LAS ACCIONES CON MAYOR PESO RELATIVO DE LOS ÍNDICES SECTORIALES BANCA, COMMODITIES, CONSUMO, INDUSTRIAL Y RETAIL DE LA BOLSA DE COMERCIO DE SANTIAGO DE CHILE" del alumno Luis Alfredo Oliva Silva.

Teniendo en cuenta las exigencias de la Carrera de Ingeniería Comercial y en especial las referidas a la actividad de titulación, la comisión de examinación califica el presente informe con 6.4 puntos (escala de 1 a 7).

Atentamente,


Juan Cabas Monje
Profesor Guía


Bernardo Vásquez
Profesor Informante


Omar Asina M.
Director de Escuela

CC. - Director de Escuela Ingeniería Comercial
- Alumnos(as)
- Archivo

AGRADECIMIENTOS

LUIS ALFREDO OLIVA SILVA

A mi familia por su confianza, amor y apoyo constante

A mi pareja Constanza Olguín por su compañía, amor, apoyo y ánimos incondicionales

Al profesor Juan Cabas Monje, por confiar en mí para este tema, por su guía y su optimismo constante

Y todos mis Amigos, conocidos y colaboradores de la Universidad del Bío-Bío por su excelente disposición además de su generosa y desinteresada colaboración

ÍNDICE GENERAL

INDICE GENERAL

INDICE GENERAL	5
LINEAMIENTOS GENERALES DE LA MEMORIA	9
Objetivos Generales.....	9
Objetivos Específicos	9
Justificación del Proyecto Propuesto.....	10
1. CAPITULO I:	12
PREDICCIÓN DE LOS MERCADOS ACCIONARIOS	12
1.1 Sobre la conducta de inversión	12
1.2 Eficiencia de mercado.....	12
1.3 Técnicas de Predicción	13
1.4 Análisis Técnico	14
1.4.1 Supuestos del Análisis Técnico.....	15
1.4.2 Tipos de graficos del análisis técnico.....	15
Figura 1: descripción del grafico de velas	16
1.4.2.2 Graficos de líneas	16
Figura 2: Gráfico de líneas	16
1.5 Análisis fundamental	17
1.6 Análisis Fundamental V/S Técnico	17
1.7 metodos de series de tiempo	18
1.7.1 Estacionariedad	19
1.7.2 Análisis de series de tiempo.....	19
1.8 Metodos de “machine learning”.....	19
1.8.1 Nearest NeighboR	20
Figura 3: Ejemplo de cómo funciona el método Nearest Neighbors.....	20
1.9 Redes Neuronales	20
Figura 4: Esquema de una red Neuronal	21
2. CAPITULO II:	25
REDES NEURONALES ARTIFICIALES	25
Figura 5: Neurona Biológica o Humana.....	26
2.4 Estructura de una red neuronal	26
2.4.1 Entradas y salidas	27
2.4.2 Regla de Propagación.....	27

2.4.3	Función de Transferencia.....	28
	Figura 5 Neurona con 1 entrada y función de activación lineal (4.0)	29
	29
	Figura 6: Neurona con 2 entradas y función de activación lineal.....	29
2.4.4	Función de Salida.....	30
2.5	Tipos de Redes neuronales.....	30
2.5.1	Red lineal (linear).....	30
2.5.2	El Perceptrón multicapa (MLP)	31
2.5.3	Red de Función de base radial (RBF)	31
2.5.4	Redes Neuronales de Regresión generalizadas (GRNN)	33
2.6	Capacidad de generalización de la red.....	33
	Figura N°7: Ejemplo de una red sobreentrenada y entrenamiento correcto de una red.	33
2.6.1	Validación Cruzada (Cross. Validation)	34
3.	CAPITULO III METODOLOGIA	36
3.1	Elección de los modelos RNA adecuados	36
3.2	Selección de la muestra.....	36
3.2.1	Selección de las acciones	36
3.3	Definición de variables	37
3.3.1	Variable Objetivo (desired).....	38
3.3.2	Precios	38
3.3.3	Indicadores técnicos	38
3.3.4	Otras Variables.....	39
3.3.5	Tratamiento de los Datos Perdidos.....	40
3.3.6	Proceso de entrenamiento de la red.....	40
4.	CAPITULO IV RESULTADOS	43
4.0	análisis previos a los resultados	43
4.0.1	RESULTADOS PARA LA ACCION DE FALABELLA	44
	Gráfico de la serie con modelo arima.....	47
	Gráfico de la serie con el modelo holt- winters:.....	47
	Accuracy Modelo de Redes Neuronales Falabella.....	48
	Gráfico de la serie con redes neuronales:	48
4.1	RESULTADOS PARA LA ACCION LAN	48
	modelo arima para la accion lan	50
	modelo holt-winters para la accion lan.....	50

Accuracy Holt-Winters LAN.....	50
modelo RNA para la accion lan.....	51
Accuracy Modelo NN LAN	51
4.2 RESULTADOS PARA LA ACCION COPEC	52
grafico con el modelo arima	53
summary(arcopec)	53
grafico con el modelo holt-winters.....	54
Accuracy HW COPEC	54
grafico con el modelo rna	55
Accuracy NN COPEC	55
4.3 RESULTADOS PARA LA ACCION CHILE	55
grafico para el modelo arima:.....	57
grafico de la serie con el modelo wh:	58
accuracy(forchilehw,chile.ts3).....	58
grafico de modelo rna.....	58
accuracy rna chile	58
4.4 RESULTADOS PARA LA ACCIÓN CCU	59
grafico modelo arima para ccu	60
resumen modelo arima para la accion ccu.....	60
grafico modelo hw para ccu.....	61
grafico del modelo rna para la accion ccu	61
5 CAPITULO V CONCLUSION	64
6 ANEXOS.....	63
6.1 datos de la accion falabella	66
6.1.1 modelo arima falabella.....	66
6.1.2 metodo de holt-winters falabella.....	68
6.2.1 holt-winters lan.....	76
6.3 modelo arima copec	81
6.3.2 mmodelo nn copec	87
6.4 modelo arima para chile.....	89
6.4.1 modelo hw y pronóstico	91
6.4.2 modelo nn chile	95
6.5 modelo arima para ccu	97
BIBLIOGRAFÍA	106

LINEAMIENTOS GENERALES

LINEAMIENTOS GENERALES DE LA MEMORIA

OBJETIVOS GENERALES

Analizar el desempeño de un modelo de red neuronal artificial, comparado con distintos métodos de pronósticos tradicionales sobre los precios en forma semanal de las acciones con mayor peso relativo de los Índices Sectoriales:

- ✓ Banca (CHILE)
- ✓ Commodities (COPEC)
- ✓ Consumo (CCU)
- ✓ Industrial (LAN)
- ✓ Retail (FALABELLA)

Presentes la Bolsa de Comercio de Santiago de Chile.

OBJETIVOS ESPECÍFICOS

- ✓ Desarrollar una base de datos y realizar un análisis estadístico (modelos ARIMA y Wolt-Winters) de las acciones CHILE, COPEC, CCU, LAN y FALABELLA correspondientes a las empresas con mayor peso relativo en los sectores que pertenecen sobre los datos de la Bolsa de Comercio de Santiago de Chile.
- ✓ Determinar los modelos de RNA¹ adecuados para el modelamiento de las variaciones de precios de las acciones mencionadas anteriormente.
- ✓ Identificar los puntos críticos y los factores que afectan la aplicación de las RNA en la predicción de las variaciones de precios.
- ✓ Analizar si el modelo de RNA tiene capacidad predictiva, y junto con esto ver si se traduce en beneficios económicos.

¹ RNA: Redes Neuronales Artificiales

JUSTIFICACIÓN DEL PROYECTO PROPUESTO

La mayoría del tiempo nos encontramos en situaciones de incertidumbre, donde debemos tomar decisiones “riesgosas”. Una de las características de los Mercados de cualquier tipo, como los financieros, es que son dinámicos e inciertos. Dado esto, la persona que invierte en este mercado debe ser lo suficientemente capaz, tanto en la habilidad de gestionar y reducir el margen de error en su toma de decisiones de inversión.

Durante el último tiempo, las redes neuronales son aplicadas en muchas áreas como la geología, física o matemáticas. En el área de las Finanzas se han aplicado para predecir precios de Commodities como el oro, la probabilidad de quiebra(Serrano, Carlos ; Martín del Brío, 1993), hasta incluso la probabilidad de una evaluación crediticia, entre muchas otras aplicaciones.

El propósito de esta memoria es evaluar el desempeño de los modelos de redes neuronales artificiales en las variaciones del precio, suponiendo un administrador de carteras de inversión o inversionista que hubiese seguido las recomendaciones de compra y venta dadas por las predicciones del modelo, conformando su portafolio de forma semanal, durante un tiempo determinado (15 años aproximadamente para evaluar realmente el desempeño logrado por esta herramienta en diversos escenarios de los modelos a desarrollar para de esta manera obtener resultados y conclusiones robustas). De acuerdo a estudios realizados en Chile y en el extranjero, las redes neuronales muestran un buen desempeño en la aplicación para el pronóstico de retornos accionarios(“Vol. 13, N°1, Otoño 2006, Parisi, Rebolledo, Cornejo.pdf,” n.d.)

Este trabajo constituye la primera memoria realizada en el Departamento de Gestión Empresarial de la Universidad del Bío-Bío, que utiliza la metodología de redes neuronales artificiales para el pronóstico de las acciones más representativas de los índices sectoriales mencionados con anterioridad del Mercado Bursátil Chileno.

CAPITULO I: PREDICCIÓN DE LOS MERCADOS ACCIONARIOS

1. CAPITULO I:

PREDICCIÓN DE LOS MERCADOS ACCIONARIOS

1.1 SOBRE LA CONDUCTA DE INVERSIÓN

Para dar algunas luces sobre el desempeño que tienen los mercados accionarios de nuestra actualidad, debemos conocer el comportamiento de sus inversionistas, reflejado en sus decisiones de tanto compra como también venta. Al respecto existen 2 hipótesis que explican el funcionamiento.

La primera de ellas, Corresponde a la hipótesis de asentamiento rígido (Robb & Coleman, 2010), la cual expone que los inversionistas esperan que el precio de la acción refleje su valor fundamental. De cierta forma, esta hipótesis se complementa con los conceptos de eficiencia de mercado y análisis fundamental para la toma de decisiones en el ámbito financiero, donde el mercado está definido por el comportamiento psicológico de los inversionistas o también dicho como las finanzas conductuales.

1.2 EFICIENCIA DE MERCADO

Dicha eficiencia ha sido bastante discutida por investigadores y académicos de las finanzas. La hipótesis establecida por Fama, propone que los mercados eficientes (EMH) a través del precio de un activo es capaz de reflejar instantáneamente la información disponible en un contexto donde los agentes son racionales y cualquier incentivo posible por conllevar ganancias haciendo algún pronóstico del mercado será en vano.

De Forma generalizada, se justifica que toda la información está contenido en los precios y la llegada de nueva información, que por definición es impredecible, será absorbida inmediatamente por los precios expuestos. De manera tal que si los precios están cambiando por la venida de nueva información, el mercado se vuelve impredecible. Así, Cualquier Esfuerzo por parte de los inversionistas profesionales no generará rendimientos extraordinarios en forma perdurable en el tiempo. Es por ello que no existe espacio para la predicción(Asadi, Hadavandi, Mehmanpazir, & Nakhostin, 2012).

Como resultado de Esto, toda la información contenida en los precios pasados será reflejada en el precio de hoy de las acciones, no en el de mañana. Los parámetros de comportamientos en los precios no durarán mucho tiempo y los cambios en el precio en un periodo serán independientes de los cambios en el siguiente (Ikeda, 2004)

Las hipótesis de eficiencia del mercado se pueden generalizar a grosso modo en 3 niveles, las cuales son:

- Eficiencia Débil: No es posible predecir los precios de los activos en base a la información histórica de ellos.
- Eficiencia Semi-fuerte: Además de lo anterior, se incluye toda la nueva información pública, pero tampoco es posible predecir los precios accionarios.
- Eficiencia Fuerte: No es alcanzable predecir los precios, aun cuando se posea de toda la información tanto pública como privada.

Por Supuesto si el mercado es eficiente en sentido fuerte también lo será en el sentido semi-fuerte y débil. Por otro lado, si no cumple eficiencia en el sentido débil tampoco se verificará en sentido semi-fuerte y por ende en sentido fuerte.

De acuerdo con la hipótesis de eficiencia, el mejor pronóstico para el precio de mañana es el precio de hoy, formalmente esto implica que los precios presentan un *random walk* o un camino aleatorio.(Granados, 2011)

$$y_t = y_{t-1} + u$$

Donde y es el precio, t es la unidad de tiempo y u es un término de ruido blanco, donde $\Delta y_t = u$ que significa que es tan probable un alza como una baja en el precio.

1.3 TÉCNICAS DE PREDICCIÓN

Primero antes de describir las técnicas de predicción, interesa mostrar una definición más formas sobre que es una predicción.

Definición de Predicción:

Dada una muestra de tamaño n , $\{(x_i, y_i), i = 1, \dots, n\}$, donde $y_i = f(x_i)$, $\forall i$, entonces una función g predice a f aproximándose a ella cuando el vector $[e_1, e_2, \dots, e_n]$ es minimizado además $e_i = e[g(x_i), y_i]$ donde e es una función de error arbitraria.(Arrieta, Jaime ; Torres, Juan ; Velásquez, 2009)

Si se quiere hacer un pronóstico de los precios del mercado accionario, debemos buscar determinantes del precio y encontrar alguna relación entre ellos para luego con esas relaciones proyectar los precios hacia el futuro.

La literatura muestra algunos métodos para realizar la tarea de predecir los precios. Estos modelos se pueden clasificar en 4 grandes categorías:

- Métodos de análisis técnico
- Métodos de análisis fundamental
- Métodos tradicionales de predicción de series de tiempo
- Métodos de aprendizaje por maquinas (Machine learning methods)

Dado estos métodos, tenemos que, las metodologías van desde acercamientos muy informales (análisis de charts prices en el análisis técnico) hasta métodos formales como técnicas de series de tiempo.

La categorización de la predicción depende de qué método se está usando para predecir el mercado t que datos se están usando (variables). Sin embargo, todos los métodos tienen algo en común pues intentan explicar o predecir el comportamiento futuro del mercado en el cual se está haciendo la evaluación.

1.4 ANALISIS TECNICO

El análisis técnico es una modalidad de estudio utilizado por los inversionistas para tratar de predecir el comportamiento de un determinado instrumento financiero. Esta modalidad se sustenta en el uso de gráficos y en los movimientos pasados para tratar de proyectar su evolución en el futuro.

Se dice que esta técnica permite complementar la toma de decisiones de un inversionista que utiliza al Análisis Fundamental (basado en el estudio de toda la información económica- y financiera disponible sobre la empresa; balance, estado de resultados, ratios financieros, etc.).

1.4.1 SUPUESTOS DEL ANÁLISIS TÉCNICO

Los principales supuestos en los que se basa el Análisis Técnico son:

- El mercado es eficiente: El precio de mercado de un instrumento financiero asimila y toma en consideración toda la información disponible para el mercado. Es decir a un analista técnico (puro y fundamentalista) le bastaría sólo con ver los gráficos del precio para tomar sus decisiones de inversión, no necesitando leer el diario, conocer el negocio de la empresa, realizar un análisis económico, ni financiero.

- El precio se mueve en tendencias: La trayectoria del precio de mercado de un instrumento financiero se mueve en tendencias (alcistas, bajistas o laterales) las cuales se mantienen hasta que no ocurra un evento, (que le dé nueva información al mercado) lo suficientemente fuerte (con volumen) como para hacerla cambiar.

- La historia se repite: La evolución del precio de un instrumento financiero incluye y asimila las expectativas y estados emocionales (pesimismo, miedo, codicia, optimismo, derrotismo) de aquellos que operan en el mercado. Son todos estos factores los que han tenido cabida durante decenas de año y hacen que la historia se repita y una y otra vez.

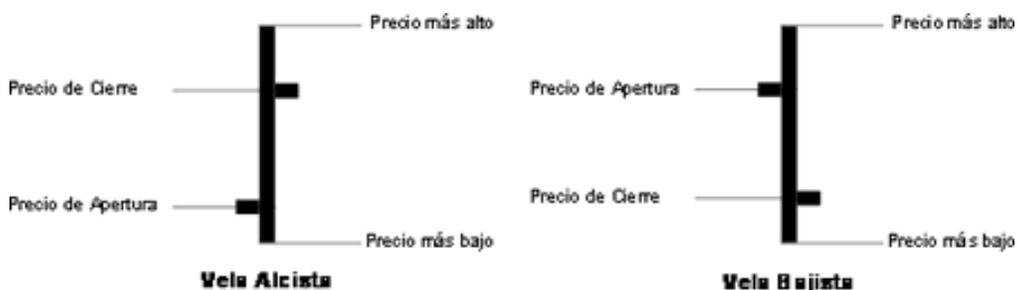
1.4.2 TIPOS DE GRAFICOS DEL ANÁLISIS TÉCNICO

1.4.2.1 GRAFICOS DE VELAS

Los gráficos de velas HLC y OHLC se elaboran dibujando una vela para cada período de análisis (un día, una semana o un período de tiempo determinado), las cuales se construyen trazando una línea vertical entre el mayor precio y el menor precio del período. A la izquierda de dicha línea se grafica una pequeña línea horizontal para denotar el precio de apertura (esto se realiza sólo para las velas OHLC), mientras que a la derecha se grafica una pequeña línea horizontal para denotar el precio de cierre. Además, cada vela puede clasificarse como alcista o bajista (independiente de la vela que la antecede) en base al siguiente criterio:

- Si el precio de cierre es mayor que el precio de apertura, se dice que la vela es alcista.
- Si el precio de cierre es menor que el precio de apertura, se dice que la vela es bajista.

Figura 1: descripción del grafico de velas

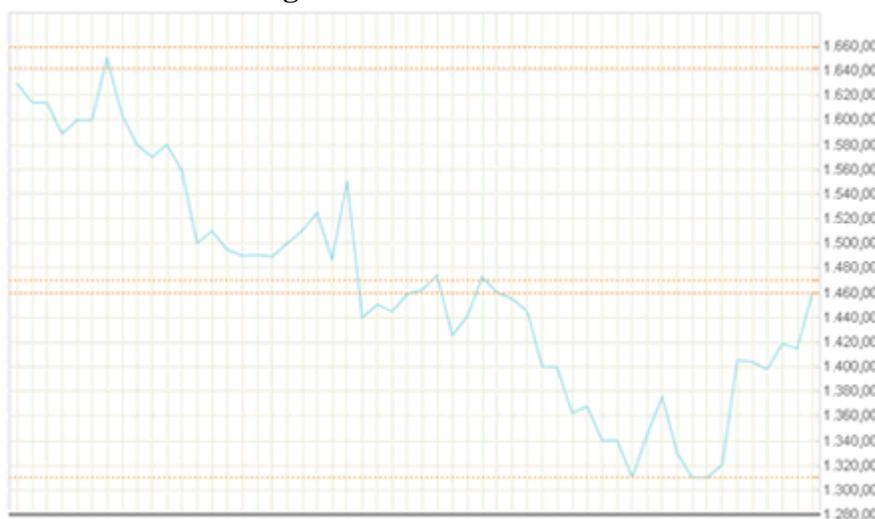


Fuente: Página web: <http://www.bolchile.cl/educate>

1.4.2.2 GRAFICOS DE LINEAS

Los gráficos de líneas se construyen uniendo mediante una línea los precios de cierre de un instrumento determinado. Si la vela actual es mayor que la vela anterior el color de tendencia asociada a ésta es el de una tendencia alcista. Si la vela actual es menor que la vela anterior el color de tendencia asociada a ésta es el de una tendencia bajista.

Figura 2: Gráfico de líneas



Fuente: Página Web <http://www.bolchile.cl/educate>

1.5 ANÁLISIS FUNDAMENTAL

En contraste al análisis técnico, el análisis fundamental se fundamenta en bases teóricas. Los analistas que utilizan este método de predicción, usan variables fundamentales para obtener estimaciones sobre la industria y sobre la empresa; por ejemplo: tasas de crecimiento, pago de dividendos, proyección de las ventas, riesgo en la inversión, entre otras. El objetivo es obtener una estimación del valor intrínseco del activo. Una regla de trading proveniente de este tipo de análisis es: Si el valor intrínseco de un activo es superior a su valor en el mercado (spot), invierta en dicho activo, de lo contrario, considere que el activo es una mala inversión.

El análisis fundamental cree que el mercado está definido en un 90% por la lógica y en un 10% por el factor psicológico

1.6 ANÁLISIS FUNDAMENTAL V/S TÉCNICO

El primer principio del Análisis Técnico dice que cualquier evento que pueda afectar a la acción en el mercado, está descontado en el precio de manera ponderada. Por lo tanto, sostiene que no es necesario conocer los fundamentales o noticias que causan un movimiento en el precio, sino que es suficiente analizar las gráficas. De hecho, los analistas técnicos puristas insisten en aislarse de la información fundamental, argumentando que es humanamente imposible enterarse de todas las noticias.

Mientras que el Análisis Técnico se concentra en el estudio de la acción del mercado, el Análisis Fundamental se enfoca en las fuerzas económicas de oferta y demanda que llevan al precio a subir, bajar o permanecer sin cambios.

El enfoque fundamental analiza todos los factores relevantes que afectan el precio de un instrumento financiero para así determinar el valor intrínseco de éste (valor intrínseco es el precio que los analistas fundamentales señalan como el que realmente vale, basado en la ley de oferta y demanda). Si el valor intrínseco está por debajo del valor actual, entonces el mercado está sobrevaluado y debe ser vendido. Si el valor intrínseco está por encima del valor actual, entonces está subvaluado y debe comprarse.

Ambos enfoques pretenden resolver el mismo problema: Predecir la dirección que el precio podría tener en el futuro. Mientras que los fundamentalistas estudian las causas del movimiento, los analistas técnicos estudian sus consecuencias.

La mayoría de los operadores de mercados se clasifican como fundamentales o técnicos, aunque en la realidad tienden a coincidir en un gran terreno común. La mayoría de los fundamentalistas tienen cuando menos conocimientos funcionales del análisis gráfico, mientras que los analistas técnicos se mantienen al tanto de los fundamentales. El problema es que las gráficas y los fundamentales frecuentemente parecen contraponerse. Algunas veces, al inicio de cambios importantes en las tendencias, los fundamentales no parecen poder explicar lo que el mercado está haciendo. En estos momentos es cuando ambos enfoques se distancian y contradicen más. Conforme el movimiento en el precio se desarrolla, el enfoque técnico y el fundamental tienden a converger nuevamente.

Una posible explicación es que la acción del mercado tiende a llevar la delantera a los fundamentales conocidos. Mientras que los fundamentales que ya se han dado a conocer han sido descontados en el precio, el mercado empieza a descontar aquellos fundamentales que no son de dominio público todavía. Frecuentemente los grandes cambios de tendencia comienzan con muy pocas noticias que los apoyen. Para el momento en que los fundamentales confirman el cambio de tendencia, el movimiento ya ha avanzado considerablemente.

El analista técnico se considera en ventaja respecto del analista fundamental, ya que estudiar los fundamentales no necesariamente permite analizar la acción del precio sino que también saber cuándo ingresar o salir del mercado.

1.7 METODOS DE SERIES DE TIEMPO

La econometría de series de tiempo, cuenta con bastantes modelos para el pronóstico de las mismas, además de los métodos tradicionales, como las regresiones, de las cuales se desprenden tanto los modelos univariados y los modelos multivariados, dependiendo del número de variables explicativas que se suponen del modelo.

Los métodos para análisis de series de tiempo, aceptan que las observaciones estadísticas de la serie, estén en intervalos regulares de tiempo. También se asume que las series son procesos estacionarios o no evolucionados, las cuales tienen particularidades estadísticas que son variantes a través del tiempo, tales como:

1.7.1 ESTACIONARIEDAD

Se dice que es un proceso Estocástico es estacionario si su media y su varianza es constante en el tiempo y si el valor de la covarianza entre 2 periodos depende solo de la distancia o rezago entre estos 2 periodos y no del tiempo en cual se ha calculado la covarianza (gujarati, 1997).

Además podemos contrastar con otros modelos como los Box & Jenkins, el objetivo de obtener una serie estacionaria, es lograr identificar un modelo estocástico que pueda ser interpretado como generador de la información muestral y que si se utiliza para fines predictivos, es necesario que dicho modelo posea características que permanezcan a través del tiempo.

1.7.2 ANÁLISIS DE SERIES DE TIEMPO

Se logra identificar 2 tipos distintos pero en general muy similares modos de análisis de series de tiempo. Por un lado están los métodos de tiempo-dominio (time-domain) que se basan en la teoría de la correlación estadística puesto que se puede desarrollar a la vez, variantes sofisticadas de los modelos de regresión tradicionales, estos métodos (time-domain) ejecutan o trabajan con las funciones de auto covarianza y las funciones de covarianza de corte transversal, e inevitablemente son métodos paraméricamente estructurados. A la vez existen 2 tipos de modelos de tiempo-dominio, estos son los PM o promedios móviles y auto regresivos (AR, MA) para “single” series y los métodos de función de transparencia.

Otra forma de poder explicar los análisis de series de tiempo se basa en los métodos de análisis espectral. Estos Están basados en extensiones de los métodos de análisis de Fourier y se fundamentan en la idea de que cualquier función analítica sobre un intervalo finito puede ser aproximada con un grado de precisión dad, tomando la suma ponderada de las Seno y Coseno de frecuencias armónicamente crecientes.

1.8 METODOS DE “MACHINE LEARNING”

Gran Cantidad de Métodos de aprendizaje inductivo han sido desarrollo bajo el nombre de “machine learning” o aprendizaje de máquina. Sin embargo, en la predicción de los mercados Financieros sobresalen 2 de estos métodos: *limite más cercano (Nearest Neighbor)* y *redes neuronales artificiales (artificial neural Networks)*.

1.8.1 NEAREST NEIGHBOR

Se utiliza básicamente o frecuentemente en la clasificación de datos, en donde la herramienta más clara para la identificación se realiza a través de la distancia euclidiana.

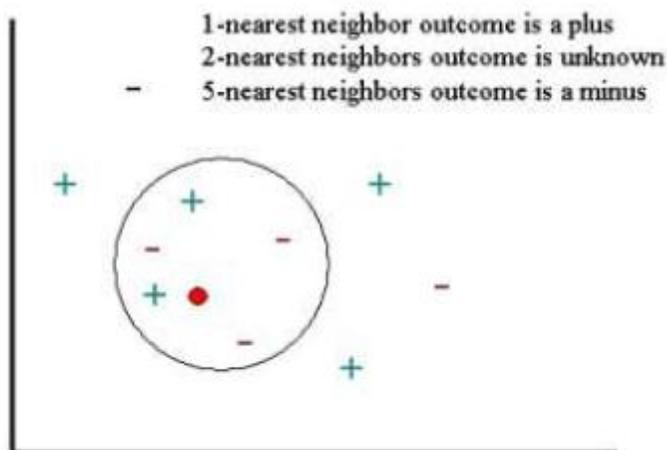


Figura 3: Ejemplo de cómo funciona el método Nearest Neighbors.

La figura anterior nos muestra la forma de entender la forma de funcionamiento del Nearest Neighbor Method, en un problema de clasificación. La idea es determinar que signo tendrá el punto. Plus (+) o minus (-) en base al análisis de K-nearest neighbors.

1.9 REDES NEURONALES

El Avance de las tecnologías a lo largo de las pasadas décadas ha permitido desarrollar, innovar y poner en práctica metodologías nuevas y otras antiguas. Que por razones de la tecnología no era posible implementar. Una de estas metodologías son las Redes Neuronales Artificiales (ANN).

Las ANN son sistemas complejos de procesamiento de datos que tratan de emular las características del cerebro humano. Algunos de los usos de las ANN son:

- Análisis de Riesgo Crediticio.
- Medición de los niveles de Riesgo.
- Proyecciones económicas y financieras.

- Minería de Datos
- Automatización

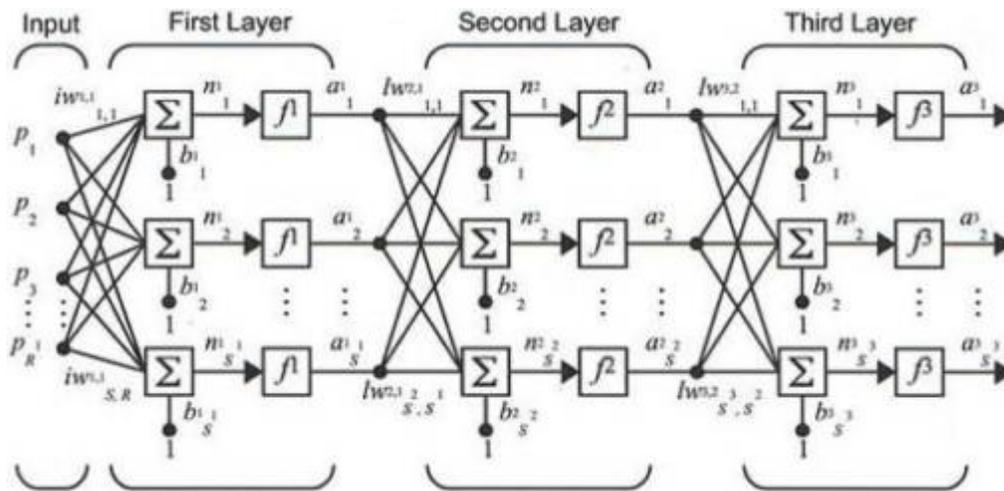


Figura 4: Esquema de una red Neuronal

Dentro de este grafico podemos evidenciar que se puede ver que las neuronas se encuentran agrupadas por capas, cada una de las capas está compuesta por un número variable de neuronas, que comparten un comportamiento similar. El conjunto de capas es el que va formando una red neuronal. Además podemos definir que el grafico se encuentran 3 tipos de capas, tales como:

1. Input Layer o Capa de Entrada.
2. Hidden Layer o Capas Ocultas.
3. Output Layer o Capa de Salida.

La neurona de la capa de entrada (Input Layer), tiene tantas conexiones como neuronas tenga la capa de oculta, y a su vez la capa oculta recibirá tanta información como neuronas tenga la capa de entrada. En la figura es posible apreciar que la primera capa es la encargada de agrupar a las neuronas que reciben los datos de entrada al problema y su número dependerá de los datos de entrada. La característica de esta capa es que es la única capa que no tiene funciones de transferencia. En la gráfica es posible ver que hay 2 niveles de capas ocultas, donde el número de capas ocultas puede variar desde ninguna o más de una, dependiendo de la complejidad del problema que se quiere solucionar con la red. Mediante un tratamiento adecuado, se consiguen las propiedades de generalización, extracción, adaptabilidad, entre otras. La característica de este nivel es que en el ocurre un proceso matemático que permite determinar el potencial sináptico que será introducido en la función de transferencia.

Finalmente en la capa de salida, el número de neuronas de esta capa depende del formato que se esperada de salida de la red. En el siguiente capítulo se discutirá y se abordará el tema en mayor profundidad.

1.10 MODELOS ARIMA.

El modelo ARIMA necesita identificar los coeficientes y número de regresiones que se utilizarán. Este modelo es muy sensible a la precisión con que se determinen sus coeficientes.

Se suele expresar como ARIMA(p,d,q) donde los parámetros p , d y q son números enteros no negativos que indican el orden de las distintas componentes del modelo — respectivamente, las componentes autorregresiva, integrada y de media móvil. Cuando alguno de los tres parámetros es cero, es común omitir las letras correspondientes del acrónimo — AR para la componente autorregresiva, I para la integrada y MA para la media móvil. Por ejemplo, ARIMA(0,1,0) se puede expresar como I(1) y ARIMA(0,0,1) como MA(1).

El modelo ARIMA puede generalizarse aún más para considerar el efecto de la estacionalidad. En ese caso, se habla de un modelo SARIMA (*seasonal autoregressive integrated moving average*).

El modelo ARIMA (p,d,q) se puede representar como:

$$Y_t = -(\Delta^d Y_t - Y_t) + \phi_0 + \sum_{i=1}^p \phi_i \Delta^d Y_{t-i} - \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t$$

en donde d corresponde a las d diferencias que son necesarias para convertir la serie original en estacionaria, ϕ_1, \dots, ϕ_p son los parámetros pertenecientes a la parte "autorregresiva" del modelo, $\theta_1, \dots, \theta_q$ los parámetros pertenecientes a la parte "medias móviles" del modelo, ϕ_0 es una constante, y ε_t es el término de error (llamado también *innovación*).

Se debe tomar en cuenta que:

$$\Delta Y_t = Y_t - Y_{t-1}$$

1.11 MODELOS HOLT WINTERS

El método de Holt-Winters es básicamente un procedimiento de suaviamiento exponencial. Este tipo de procedimiento, ps facilitan los cálculos y reducen los

requerimientos de almacenamiento en las bases de datos, lo cual cobra importancia cuando se están prediciendo muchas series de tiempo.

Los modelos de suavizado exponencial se basan en la actualización, para cada período, de hasta tres parámetros:

Media (modelo de suavizado simple).

Media y tendencia (Holt, 1957).

Media, tendencia y estacionalidad (modelo de Holt-Winters).

Estos modelos se conocen en la literatura como de suavizado exponencial de uno, dos y tres parámetros, respectivamente. Al usar el modelo de Holt-Winters, en un período t , el patrón de comportamiento en la predicción puede estar dado por

$$D_t = (F + bt)I_t + \varepsilon_t \quad \text{o por} \quad D_t = F + bt + I_t + \varepsilon_t \quad (1)$$

Todo depende de si se considera estacionalidad aditiva o multiplicativa (\sim), donde F representa la media y e , es el error de predicción

CAPITULO II: REDES NEURONALES ARTIFICIALES

2. CAPITULO II:

REDES NEURONALES ARTIFICIALES

Como Conceptos básicos para dar paso a la definición formal de lo que es una red neuronal artificial, debemos tener claro que estas fueron originalmente una simulación abstracta de los sistemas nerviosos biológicos, constituidos por un conjunto de unidades llamadas neuronas o nodos conectados unos con otros. El primer modelo de red neuronal fue propuesto en 1943 por McCulloch y Pitts en términos de un modelo computacional de actividad nerviosa. Este modelo era un modelo binario, donde cada neurona tenía un escalón o umbral prefijado, y sirvió de base para los modelos posteriores.

Las redes neuronales artificiales, en Inteligencia Artificial, son modelos computacionales tales que imitan las redes de neuronas del cerebro con el fin de emular el comportamiento inteligente pero, también se definen como modelos paramétricos que son equivalentes a modelos no lineales de regresión. Su popularidad en la solución de diferentes problemas prácticos, como la predicción de series de tiempo, es debida a características como su robustez y tolerancia al ruido(J. D. Velasquez, 2012).

Una primera clasificación de los modelos de NN es:

2.1 Modelos inspirados en la Biología:

Estos comprenden las redes que tratan de simular los sistemas neuronales biológicos, así como ciertas funciones como las auditivas o de visión.

2.2 Modelos artificiales aplicados:

Estos modelos no tienen por qué guardar similitud estricta con los sistemas biológicos. Sus arquitecturas están bastante ligadas a las necesidades de las aplicaciones para las que son diseñados.

2.3 Redes Neuronales de tipo biológico:

Se estima que el cerebro humano contiene más de cien mil millones (10¹¹) de neuronas y 10¹⁴ sinapsis en el sistema nervioso. Los estudios realizados sobre la anatomía del cerebro humano concluyen que hay, en general, más de 1000 sinapsis por término medio a la entrada y a la salida de cada neurona. Aunque el tiempo de

conmutación de las neuronas biológicas (unos pocos milisegundos) es casi un millón de veces mayor que en las actuales componentes de las computadoras, las neuronas naturales tienen una conectividad miles de veces superior a la de las artificiales. El objetivo principal de las redes neuronales de tipo biológico es desarrollar operaciones de síntesis y procesamiento de información, relacionadas con los sistemas biológicos. Podemos definir o esquematizar de manera básica lo que especifica una red neuronal:

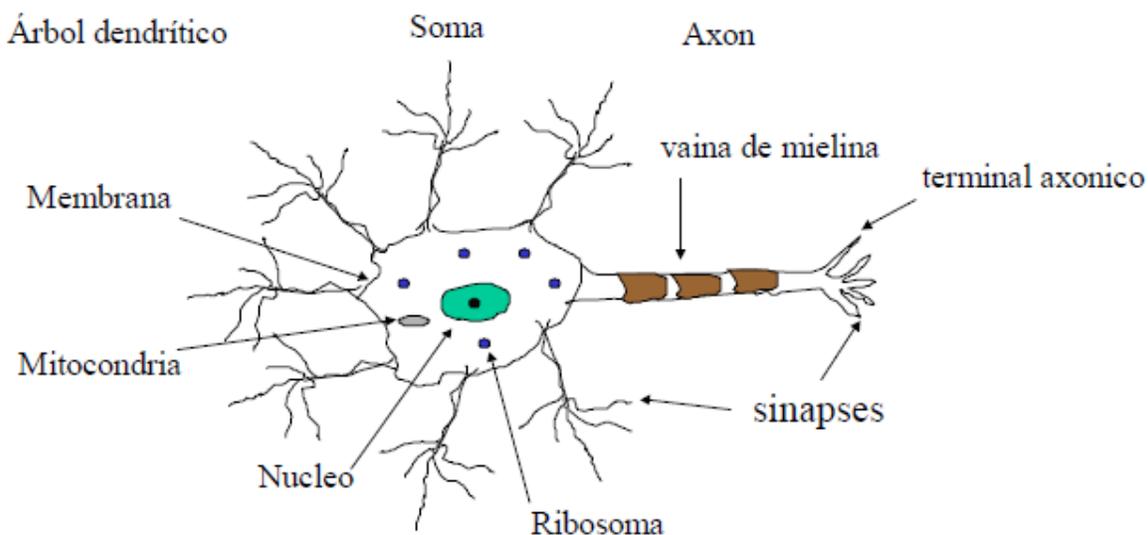


Figura 5: Neurona Biológica o Humana

Dentro de la explicación de la neurona humana, podemos resaltar que el proceso donde se produce la reacción del procesamiento de la información, es en la llamada sinapsis, la cual se muestra en el final y/o vértices de la neurona, las cuales hacen conexión con las otras neuronas produciendo el proceso sináptico.

2.4 ESTRUCTURA DE UNA RED NEURONAL

Según del Brío y Sanz (2002), existen tres conceptos claves de los sistemas nerviosos que las redes neuronales tratan de imitar, las cuales son:

Paralelismo: Los sistemas neuronales funcionan en paralelo. Es decir, algunas tareas no son secuenciales o que dependan de un seguimiento, si no que estas pueden funcionar simultáneamente, desarrollando más funciones entre sí.

Memoria Distributiva: Esto se aplica a la tolerancia a los errores eventuales a suceder, lo que se trata de demostrar es que si una neurona falla, es poca la cantidad de información que se pierde pues los sistemas neuronales están interconectados entre sí. Por ende se da que otra neurona transmitirá la información.

Adaptabilidad: Las neuronas reflejan en este significado su máximo apogeo y grandeza, la cual muestra que estas tienen la capacidad de aprendizaje sobre los hechos pasados de los sistemas neuronales

Neurona: Una Neurona o Procesador elemental (PE) es el elemento más simple de un sistema neuronal y está diseñada por un conjunto de entradas $x_j(t)$, pesos sinápticos de la neurona i w_{ij} , regla de propagación $\sigma(w_{ij}, x_j(t))$ que proporciona el valor del potencial postsináptico $h_i = \sigma(w_{ij}, x_j(t))$ de la neurona i en función de sus pesos y entradas, función de activación $fi(a_i(t-1), h_i(t))$ que proporciona el estado de activación actual $a_i(t) = fi(a_i(t-1), h_i(t))$ de la neurona i en función de su estado anterior ($a_i(t-1)$) y de su potencial postsináptico actual, función de salida $F_i(a_i(t))$ que proporciona la salida actual $y_i(t) = F_i(a_i(t))$ de la neurona i en función de su estado de activación. Luego la operación de la neurona puede expresarse como:

$$y_i(t) = F_i(fi([a_i(t-1), \sigma(w_{ij}, x_{ij}(t))]))$$

Capas: Las Capas ocultas o no son conjuntos de neuronas de un mismo nivel.

Red: Una red es un conjunto de capas de distinto nivel que esta interrelacionado

Sistema Neuronal: El Sistema neuronal agrega a la red las entradas y salidas.

2.4.1 ENTRADAS Y SALIDAS

Las variables de entrada de un modelo de red neuronal pueden ser categóricas o continuas, dependiendo del modelo y aplicación. Un ejemplo de los tipos de redes que aceptan las dos variables es el Perceptrón multicapa admite ambos tipos de señales. En este estudio se trabajará con ambos tipos de variables.

2.4.2 REGLA DE PROPAGACIÓN

La regla de Propagación permitirá obtener, a partir de las entradas y los pesos, el valor del potencial postsináptico h_i de la neurona.

$$h_i(t) = \sigma(w_{ij}, x_j(t))$$

La función típica es del tipo lineal:

$$h_i(t) = \sum_j w_{ij}, x_j$$

Este es el producto escalar de los vectores de entrada y pesos, donde W es el peso relativo y X los datos de entradas.

Otra regla de propagación utilizada frecuentemente en modelos RBF es la distancia euclídea al cuadrado:

$$h_i^2(t) = \sum_j (w_{ij} x_j)^2$$

Que representa la distancia al cuadrado el vector de entradas y el de los pesos.

2.4.3 FUNCIÓN DE TRANSFERENCIA

La función de transferencia (función de activación), proporciona el estado de activación actual $ai(t)$ a partir del potencial postsináptico $hi(t)$ y del propio estado de activación anterior $ai(t-1)$.

$$a_i(t) = fi(a_i(t-1) h_i(t))$$

Las funciones de transferencia se consideran deterministas. Donde las más usadas son las siguientes:

Función identidad: $y = x$

Escalón:

$$y = \text{signo}(x)$$

Sigmoidea:

$$y = \frac{1}{1 + e^{-x}}$$

$$Y = \tanh(x)$$

Gaussiana:

$$y = Ae^{-Bx^2}$$

Sinusoidal:

$$y = A \sin(ax + \beta)$$

Donde A y B son constantes para simplificar las expresiones.

Figura 5 Neurona con 1 entrada y función de activación lineal (4.0)

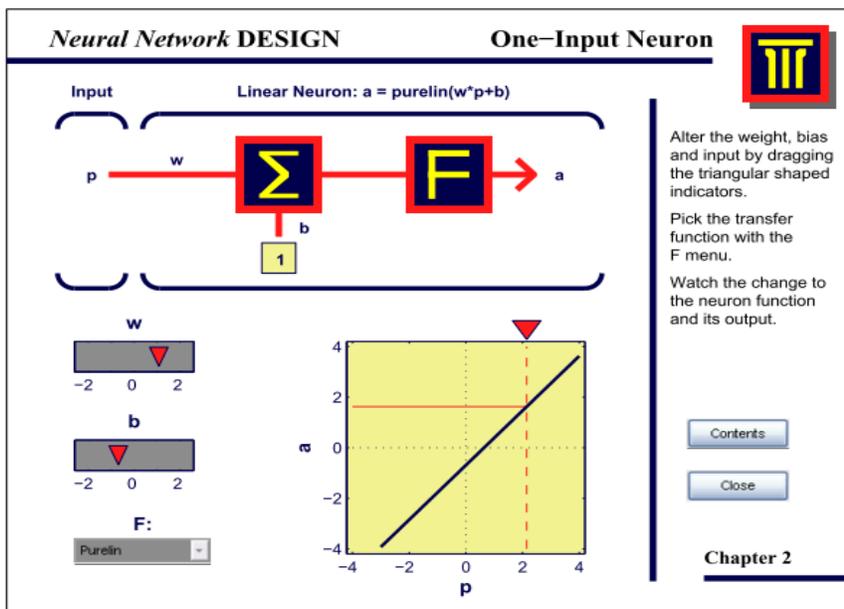
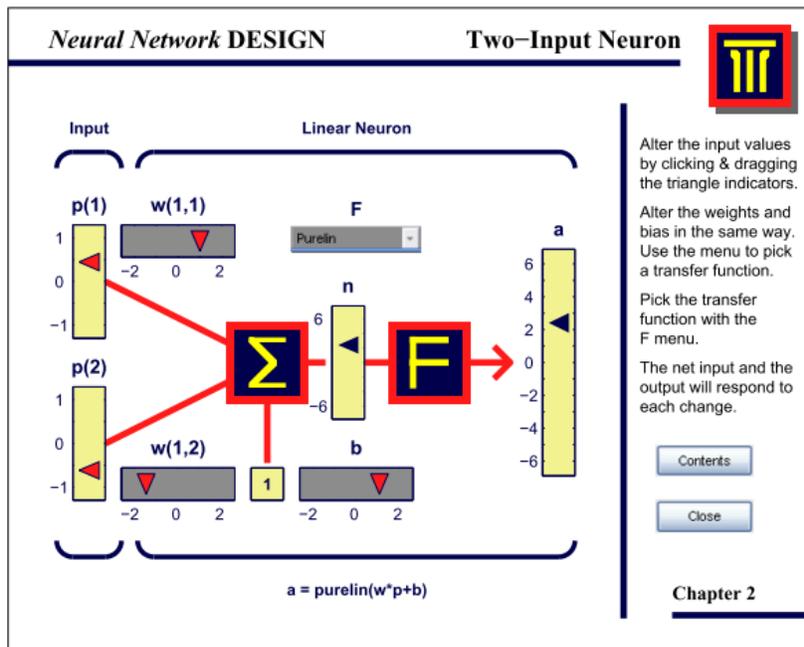


Figura 6: Neurona con 2 entradas y función de activación lineal



2.4.4 FUNCIÓN DE SALIDA

Esta Función Proporciona la salida global de la neurona $y_i(t)$, es función de su estado de activación $a_i(t)$. A menudo se utiliza la función identidad. Donde formalmente la función de salida es la siguiente:

$$y_i = F_i(a_i(t)) = a_i(t)$$

2.5 TIPOS DE REDES NEURONALES

A continuación se hará una descripción de algunas tipologías de redes neuronales usadas en problemas con series de tiempo. Es importante mencionar que existen más tipologías y en general están orientadas a la resolución de otro tipo de problemas. Por ejemplo, el procesamiento de señales en tiempo real.

Las principales tipologías de red neuronal utilizadas en el análisis de series de tiempo con entrenamiento por lotes² son:

2.5.1 RED LINEAL (LINEAR)

Es la red más simple existente, se basa en el principio de que un modelo simple se debe escoger a un modelo complejo a menos que el desempeño del modelo simple a que sea significativamente menor al del modelo complejo.

Este tipo de red no tiene capas ocultas (hidden layers), su estructura es lineal $sLI : x_j - y_i : O$, donde s indica que se trata de una red para series de tiempo, L el número de rezagos considerados, I el número de inputs, x_i el número de neuronas de entrada y_i el número de neuronas de salida y el O el número de outputs.

La red lineal consta únicamente de una capa de neuronas lineales, donde la operación del asociado lineal es:

$$y_i = \sum_{j=1}^n w_i x_j$$

Es decir, la suma ponderada de los inputs con sus pesos sinápticos.

² El entrenamiento por lotes, supone que todos los datos están disponibles al momento de entrenar la red. Como contrapartida se encuentra el entrenamiento en línea, que es típico de las redes no supervisadas (Del Brío y Molina 2002)

2.5.2 EL PERCEPTRÓN MULTICAPA (MLP)

El Perceptrón multicapa es sin lugar a dudas la arquitectura de red neuronal más popular y de mayor uso hoy en día. Sus usos se centran en: ajuste funcional (gran desempeño en ajustes no lineales), predicción de series de tiempo, clasificación, discriminación, entre otros.

La Característica del MLP, es el uso de capas ocultas y su regla de aprendizaje hacia atrás. De hecho es comúnmente llamada como red BP (back propagation) por el algoritmo que identifica el entrenamiento de esta arquitectura de red.

Formalmente una red MLP es: x_i entradas en la red, y_i las salidas de la capa oculta y z_k de salidas de la capa final: t_k serán las salidas objetivo, w_{ij} los pesos sinápticos de la capa oculta, $\equiv \sigma_j$ los umbrales de la capa oculta, w_{jk} los pesos sinápticos de la capa de salida y $\equiv \sigma_k$ los umbrales de la capa de salida. La operación de un MLP de una capa oculta y neuronas de salida lineal es:

$$z_k = \sum_j w'_{kj} y_j - \theta'_i = \sum_j w'_{kj} f \left[\sum_i w_{ji} x_i - \theta'_j \right] - \theta'_i$$

Siendo $f(\cdot)$ función del tipo sigmoideo. Esta es la estructura más común de los MLP, aunque existen variantes como: aumento de capas ocultas, arquitecturas recurrentes, etc. Funahashi (1989) demostró que mediante una MLP es posible aproximar hasta el nivel deseado cualquier función continua en un intervalo definido. Es por esto que a los MLP se les conoce como los aproximadores universales de funciones. Los algoritmos de aproximación más usados en los MLP son:

- Back propagation (BP)
- Gradiente Conjugado (CG)
- Levenberg-Marquardt (LM)
- Quickprop

2.5.3 RED DE FUNCIÓN DE BASE RADIAL (RBF)

Las RBF son similares a las MLP puesto que permiten modelar con relativa facilidad sistemas no lineales arbitrarios, del Brio y Sanz, op.cit. La diferencia fundamental entre las MLP y las RBF radica en la operación de las capas ocultas, pues las RBF operan

en base a la distancia que separa el vector de entradas respecto del vector postsináptico, cantidad a la que se le aplica una función radial con forma gaussiana.

Sea x_i las entradas de la red y_j , las salidas de a capa oculta, z_k las salidas de la capa final (y globales de la red). Cada neurona de la capa oculta almacena un vector c_{ji} (centroide), Cada una de estas neuronas calcula la distancia euclídea r_j que separa el vector de entradas x_i de su centroide

$$r_j^2 = \|X - C_j\|^2 = \sum_i [x_i - c_{ji}]^2$$

La salida de la neurona y_j se calcula a partir de una función de activación radial $\phi(r)$

$$\phi(r) = e^{-\frac{r^2}{2\sigma^2}}$$

Esta función es simétrica, el Parámetro σ mide la anchura de la gaussiana y es el radio de influencia de la neurona en el espacio de las entradas: mientras más grande es σ más amplia será la región que domina la neurona sobre el centroide.

La salida de la neurona oculta j será:

$$y_j = e^{-\frac{r_j^2}{2\sigma_j^2}} = e^{-\frac{\sum_i [x_i c_{ji}]^2}{2\sigma_j^2}}$$

Las salidas de las neuronas ocultas son a la vez entradas de la neurona de salida:

$$z_k = \sum_j w_{kj} y_j + \theta_k = \sum_j w_{kj} \phi(r_j) + \theta_k$$

Los algoritmos de entrenamiento más usados en RBF son:

1. K-medias (KM) (usado también en métodos de clasificación).
2. Optimización de mínimos cuadrados Pseudo Invertidos (PI).
3. K-Nearest Neighbors (KN).
4. Sub muestras. (SS)

2.5.4 REDES NEURONALES DE REGRESIÓN GENERALIZADAS (GRNN)

Las GRNN son similares a las RBF y las MLP, tienen características de ambas, por lo tanto se puede decir que es híbrido de estas redes. Las características de las GRNN es que tiene mejor desempeño cuando las variables categóricas del modelo son relativamente importantes. A la vez, el proceso de entrenamiento de una GRNN es extremadamente más rápido que una MLP o una RBF.

Esta arquitectura de red es nueva y los detalles matemáticos de ella no están al alcance de esta memoria, sin embargo adicionalmente se puede encontrar información referencial en algunos sitios de internet.

2.6 CAPACIDAD DE GENERALIZACIÓN DE LA RED

Podemos definir la capacidad de generalización de la red como la capacidad de dar una respuesta correcta ante patrones que no han sido empleados en su entrenamiento.

Una red que tiene un adecuado entrenamiento será capaz de generalizar.

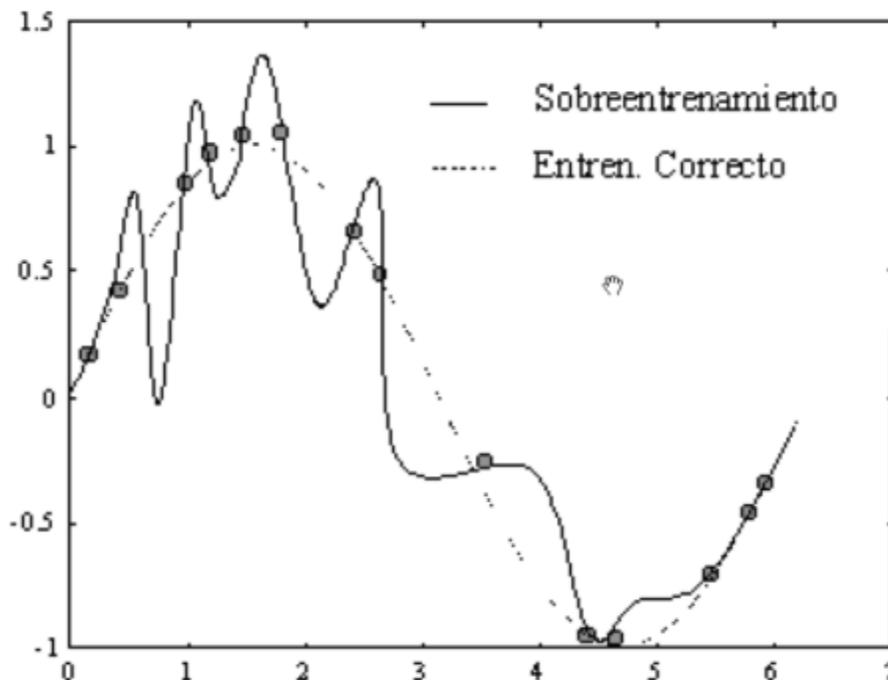


Figura N°7: Ejemplo de una red sobreentrenada y entrenamiento correcto de una red.

2.6.1 VALIDACIÓN CRUZADA (CROSS. VALIDATION)

El sobre entrenamiento de la red puede traer problemas como un sobre ajuste. Esto significa que la red aprende incluso el ruido de los datos, perdiendo la capacidad de generalización y obviamente la estacionariedad.

Para asegurar que la red pueda generalizar, se utilizan técnicas de validación. Tales técnicas dividen el conjunto de datos en distintos grupos con el objetivo de entrenar y testear la red con los indicadores de desempeño y error seleccionados

CAPITULO III: METODOLOGÍA

3. METODOLOGÍA

Previo a comenzar a detallar la metodología se hará referencia a algunos puntos importantes:

Los modelos de red neuronal, son una metodología principalmente de predicción. En ningún caso se ha pretendido explicar el comportamiento de una variable, como sucede en algunos modelos estadísticos³

Otro punto importante es que las redes no asumen ningún supuesto para hacer las predicciones. Es por esto que son clasificadas como un método no paramétrico.

3.1 ELECCIÓN DE LOS MODELOS RNA ADECUADOS

No todas las arquitecturas de redes neuronales son aptas para el modelamiento de series de tiempo. En particular, existen modelos supervisados (por ejemplo, mapas auto organizados DE Kohonen (SOFM)) y no supervisados como por ejemplo, red lineal. Modelos para análisis cluster, componentes principales, procesamiento de señales, en el marco teórico de esta memoria se expusieron los modelos típicos para el análisis de series temporales, estos son:

- Redes lineales
- Perceptron multicapa (con variantes de tiempo retardado y recurrentes)
- Redes RBF

3.2 SELECCIÓN DE LA MUESTRA

Existen redes con entrada de datos en tiempo real y redes en donde se dispone de todos los datos a analizar de una vez. Si los datos están presentes todos a la vez (como es el caso de esta memoria), lo habitual es hacer un aprendizaje por lotes (batch). En cambio si los datos llegan en tiempo real, entonces se debe utilizar un aprendizaje (entrenamiento en línea (refenes, 1995)).

3.2.1 SELECCIÓN DE LAS ACCIONES

El criterio para seleccionar las acciones, se basó en satisfacer un tamaño de muestra adecuado para el entrenamiento de las redes, además se buscó la representatividad de la acción en la medida de lo posible y uniformidad temporal de las cotizaciones. En resumen el criterio para filtrar fue:

³ Un ejemplo de modelo típicos a explicar causalidad son los modelos de regresión

- 1- De la Base de datos del sitio web de consorcio.cl, se obtuvieron las cotizaciones diarias de las acciones cotizadas en la Bolsa de Santiago de Chile.
- 2- Se filtraron las acciones, dejando solo las que pertenecen al IPSA. Se seleccionaron este tipo de acciones, Porque son las que por definición de la bolsa de Comercio de Santiago (<http://www.bolchile.cl>) Representan el mayor peso relativo de los distintos sectores de las acciones que se evalúan en la memoria.
- 3- Posteriormente se aplicó otro filtro dejando a aquellas acciones que presentan cotizaciones desde al menos de 1989. Esto nos dio un tamaño Muestral de 4372 cotizaciones por acción diaria, pero esta se redujo y se observaron las muestras semanales, estas quedaron con un tamaño de 493 muestras semanales por acción.
- 4- Por último se consideraron las acciones con mayor peso relativo dentro de los Sectores de Commodities, Industrial, Consumo, Banca y Retail.

Las acciones seleccionadas fueron:

- CHILE (Banca)
- COPEC (Commodities)
- LAN (Industrial)
- CCU (consumo)
- FALABELLA (Retail)

3.3 DEFINICIÓN DE VARIABLES

A diferencia con los métodos estadísticos tradicionales que asumen supuestos sobre las variables, como por ejemplo: no correlación entre las variables explicativas, normalidad en la distribución de la variable dependiente, estacionariedad de la serie, etc. El modelamiento de redes neuronales, dada su visión netamente predictiva y no causal, no restringe las variables con estos supuestos y resume todo el análisis a la capacidad de generalización de la red, queriendo decir con esto que cuando se trabaja con series de tiempo, algunos autores aconsejan no estacionarizar las series que no son estacionarias, ya que la red puede capturar de mejor manera la estructura (comportamiento) de la serie y por ende tendrá un mejor desempeño (demuth y beale, 2000; Patterson, 1996).

Las variables consideradas en el modelamiento del problema se obtuvieron de la siguiente forma:

3.3.1 VARIABLE OBJETIVO (DESIRED)

La variable a predecir y que también es considerada (sus rezagos) como variable de entrada, es el Precio de Cierre de las acciones semanales

3.3.2 PRECIOS

Desde la misma base de datos de Consorcio, se obtuvieron las siguientes series de tiempo:

- 1- Precio de Cierre (*close* = p_t).
- 2- Precio máximo transado durante el día (*high*_t).
- 3- Precio mínimo transado durante el día (*low*_t).
- 4- Precio Promedio durante el día (*mean*_t).

Se introdujeron estas variables por que en cierta manera reflejan el comportamiento del día a día en las transacciones bursátiles. Los *high y los low* prices muestran la variabilidad que tuvo el día en términos de cotizaciones con respecto al *mean* Price. El precio de cierre *close* captura la conclusión del trabajo diario.

3.3.3 INDICADORES TÉCNICOS

Se utilizaron además los siguientes indicadores técnicos:

Índice de Fuerza Relativa (RSI): El índice de fuerza relativa es muy usado en el análisis técnico por los traders y sirve para identificar periodos Bullish (valores Crecen hasta llegar a 100) y Brearish (valores Decrecen hasta llegar a 0). Se calcula de la siguiente forma:

$$RSI(n) = \frac{up(n)}{up(n) + |down(n)|} 100$$

Dónde:

$$up(n) = \frac{\sum_{i=t-\omega}^t \Delta P_i}{n} ; \forall \Delta P_i > 0 ; \omega = \{0, 1, 2, \dots, n-1\}$$

$$down(n) = \frac{\sum_{i=t-\omega}^t \Delta P_i}{n} ; \forall \Delta P_i < 0 ; \omega = \{0, 1, 2, \dots, n-1\}$$

Y

$$\Delta P_i = P_i - P_{i-1}$$

Se utilizó un RSI(9) para capturar la fuerza de corto plazo de la acción.

Promedios Móviles *MovAvg(n)* Los promedios móviles capturan la tendencia de la serie, el orden n del promedio móvil especifica si se quiere obtener una descripción de corto o mediano plazo. Se utilizaron promedios móviles de orden 10 y 20.

La metodología de cálculo es:

$$MovAvg(n) = \frac{\sum_{i=t-\omega}^t P_i}{n} ; \omega = \{0, 1, 2, \dots, n - 1\}$$

3.3.4 OTRAS VARIABLES

También se introdujeron al modelo variables categóricas como el día de la semana. Como También se consideraron otras variables cuantitativas, estas son:

- Fecha: La fecha es una forma de introducir el tiempo en el análisis. En este sentido, los modelos de redes neuronales son similares a los modelos de regresión para series de tiempo, que incluyen una variable de tiempo para capturar el aporte real de las variables regresoras (Gujarati, 1997).
- Cantidad de títulos Transados: Esta variable refleja el dinamismo del mercado, Por lo general, cuando una acción madura, la cantidad transadas aumentan significativamente, llegando la acción hasta un peak y posteriormente cae rápidamente, donde la cantidad de títulos transada en la etapa bearish, es significativamente menor (Meli, 2002)

- Variación absoluta del precio con respecto al día anterior: $\Delta P_i = P_i - P_{i-1}$

No se debe olvidar que la red neuronal “interpreta los datos y que cada variable es procesada por una neurona en particular, dando un trato a cada variable. Refenes op.Cit. Recomienda utilizar variables que capturen la mayor parte del espectro de posibilidades del problema.

3.3.5 TRATAMIENTO DE LOS DATOS PERDIDOS

Los valores perdidos requieren de una atención cuidadosa, ya que se necesita una interpretación (por parte de la red) lo más cercana a la lógica real de la serie.

El tratamiento de los valores perdidos fue el siguiente:

Los días en que la acción no se cotizó, en lugar de un valor perdido, el precio de cierre se reemplazó por el valor de la última cotización disponible y se estableció un $q = 0$ y precios mínimo, máximo y promedio iguales al precio de cierre $P_t = P_{t-1} = low_t = high_t = mean_t$. Con ese criterio se completaron todos los valores perdidos y se calcularon los retornos porcentuales diarios y los demás indicadores técnicos.

3.3.6 PROCESO DE ENTRENAMIENTO DE LA RED

Para entrenar las redes se utilizó el Software libre R Project versión 3.0.2, junto a sus Packages “fpp”, “forecast”, “nnet”

Esta herramienta analiza los datos y establece las siguientes variantes óptimas para cada red:

- Número de neuronas en cada capa.
- Rezagos óptimos para cada variable.
- Capas ocultas.
- Pesos iniciales.
- Parada del entrenamiento.
- Tipologías de red relevantes.
- Cantidad de datos para entrenamiento y validación.

De manera más definida podemos explicar que se trataron de entrenar los datos por medio de una red neural univariada la cual se trató del precio de cierre de forma semanal del año 2013, donde esta dio datos de 52 precios por acción.

Por lo mismo acá queda demostrado el análisis de los datos de acuerdo a lo siguiente:

Pronósticos del paquete de R “nnet” para una red neuronal de serie temporal o mejor dicho una Feed-forward de redes neuronales con una sola capa oculta y entradas retardadas para pronosticar series univariadas

```
nnetar(x, p, P=1, size, repeats=20, lambda=NULL)
## S3 método para la clase 'nnetar'
Forecast(objet, h=ifelse(objeto$m>1, 2*objeto$m, 10),
Lambda=objeto$lambda, ...)
```

De los cuales significan:

- X: Un vector o series temporales numéricas
- p: Para las series de tiempo no estacional , el valor predeterminado es el óptimo número de retardos (de acuerdo con la AIC) para un AR lineal (p) modelo . Para uso estacional series de tiempo, el mismo método que se utiliza, pero aplicado a datos desestacionalizados (a partir de una descomposición STL).
- P: Número de retardos estacionales utilizados como insumos.
- Size: Número de nodos en la capa oculta. El valor predeterminado es la mitad del número de entradas o nodos más 1.
- Repeat: Número de redes para adaptarse a diferentes pesos iniciales aleatorios. Estos son a continuación, un promedio de al producir pronósticos.
- Lambda: Box- Cox transformación de parámetros.
- Object: Un objeto de nnetar clase generada por nnetar.
- H: Número de períodos para el pronóstico.
- ...: Otros argumentos.

Detalles

Una red neuronal Feed-Forward está equipada con valores rezagados de x como entradas y una sola capa oculta con nodos de tamaño. Las entradas son para GAL 1 a p , y LAG m a MP donde $m =$ la frecuencia (x) .El total de las redes de repeticiones están equipados , cada uno con pesos iniciales aleatorios. Estos se promedian al calcular pronósticos. La red está capacitada para un solo paso de pronóstico. Las previsiones de varios pasos se calculan de forma recursiva. El modelo ajustado se llama un modelo nnetar (p , P) y es análogo a un (, P 0,0) modelo ARIMA (p , 0,0) , pero con funciones no lineales .

Valor:

Nnetar devuelve un objeto de la clase " nnetar " . forecast.nnetar devuelve un objeto de la clase " previsión". El resumen de función se utiliza para obtener e imprimir un resumen de los resultados, mientras que la función plot produce un gráfico de los pronósticos. Las funciones de acceso genéricos fitted.values y residuos extraen características útiles del valor devuelto por nnetar.

CAPITULO IV: RESULTADOS

4. RESULTADOS

4.1 ANÁLISIS PREVIOS A LOS RESULTADOS

Para demostrar la capacidad predictiva de la red neuronal univariada, utilizamos las metodologías de box-jenkins (ARIMA) y Holt-Winters, por lo que a través de los errores o medidas de evaluación por la cual se puede ajustar la efectividad del modelo, utilizaremos solo 2 de los 8 errores estadísticos descritos por el programa R, donde a través de ellos se basan los ajustes para demostrar los 3 modelos a utilizar en los resultados de los pronósticos descritos, y estos son:

$$ME = \frac{1}{T} \sum_{i=1}^T e_i \quad MSE = \frac{1}{T} \sum_{i=1}^T e_i^2 \quad MAE = \frac{1}{T} \sum_{i=1}^T |e_i|$$

$$MPE = \frac{1}{T} \sum_{i=1}^T 100 \times \left(\frac{e_i}{y_i} \right) \quad MAPE = \frac{1}{T} \sum_{i=1}^T 100 \times \left(\left| \frac{e_i}{y_i} \right| \right)$$

$$U_1 = \frac{\sqrt{\frac{1}{T} \sum_{i=1}^T (y_i - f_i)^2}}{\sqrt{\frac{1}{T} \sum_{i=1}^T y_i^2} + \sqrt{\frac{1}{T} \sum_{i=1}^T f_i^2}}$$

$$U_2 = \frac{\sqrt{\frac{1}{T} \sum_{i=1}^{T-1} \left(\frac{f_{i+1} - y_{i+1}}{y_i} \right)^2}}{\sqrt{\frac{1}{T} \sum_{i=1}^{T-1} \left(\frac{y_{i+1} - y_i}{y_i} \right)^2}}$$

Dónde:

- n : número de datos
- y' : dato real en el tiempo x
- y : pronóstico en el tiempo x

A continuación y tal como se comentó en el capítulo anterior, se mostrarán tablas resumen de las acciones (datos semanales) junto a los pronósticos de las metodologías Arima, Holt Winters y la Red Neuronal

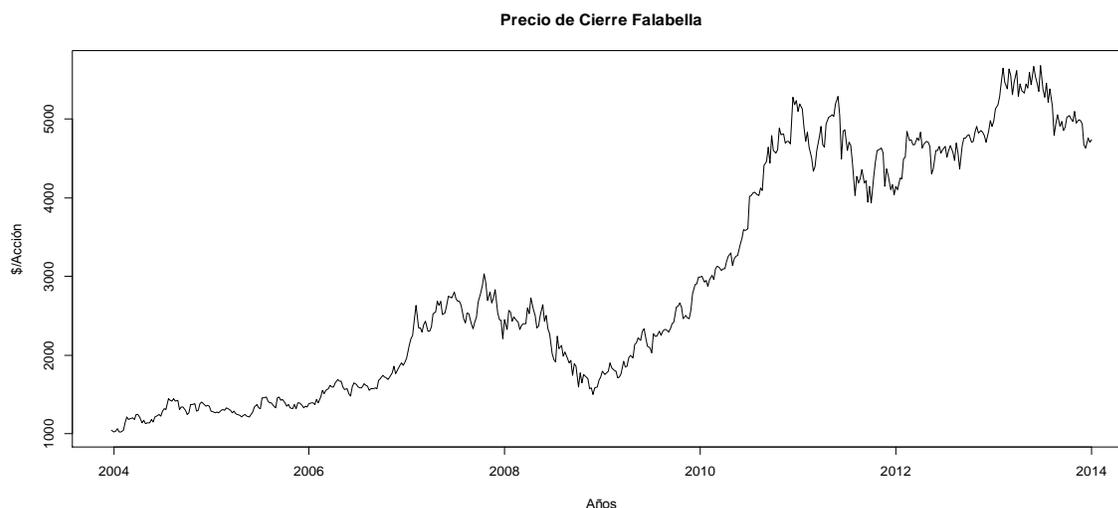
Cabe mencionar que además en las tablas se encontrarán las diferencias entre cada modelo con los valores reales de las series.

Y además cuando aparezca la palabra accuracy y/o Error measures se demostrará la veracidad de los ajustes de los errores en cada modelo donde queda al descubierto el mejor modelo de predicción (El mejor pronóstico es el que en el error del menor número más cercano al valor 0).

Por último y no menos importante para los cálculos de los modelos se establecieron los siguientes parámetros en el software R, el primero es que para el modelo ARIMA, se estableció un parámetro para que el programa encontrara el modelo que se ajustara mejor a la serie (auto.arima), para el modelo de suaviamiento exponencial se utilizaron tanto factores multiplicativos (de no estacionalidad) como aditivos (estacionarios) y para el modelo por el cual se desarrolló esta memoria de título, se utilizaron varios modelos pero del que dio un mejor resultado en el entrenamiento de la red fue de hacer un ajuste en los datos de entrada de 8, con 5 nodos y 1 capa oculta.

4.2 RESULTADOS PARA LA ACCION DE FALABELLA

Serie Original:



PRONOSTICOS DE LA ACCIÓN FALABELLA AÑO 2013

SEMANA	ARIMA	HW	RNA	P. REAL	DIF AR	DIF HW	DIF RN
S1	4920,54	4897,104	4197,902	5129,20	208,66	232,10	931,30
S2	4932,928	4778,173	4176,174	5180,00	247,07	401,83	1003,83
S3	4929,824	4739,444	4283,637	5290,00	360,18	550,56	1006,36
S4	4940,906	4637,602	4333,247	5483,80	542,89	846,20	1150,55
S5	4929,74	4652,613	4498,402	5650,00	720,26	997,39	1151,60
S6	4936,219	4678,396	4573,562	5465,00	528,78	786,60	891,44
S7	4918,98	4677,592	4768,064	5385,10	466,12	707,51	617,04
S8	4939,337	4605,608	4728,733	5643,00	703,66	1037,39	914,27
S9	4948,009	4631,347	4702,048	5550,00	601,99	918,65	847,95
S10	4962,528	4726,268	4645,376	5311,00	348,47	584,73	665,62
S11	4970,243	4790,2	4686,171	5470,00	499,76	679,80	783,83
S12	4970,326	4763,213	4748,17	5613,32	642,99	850,11	865,15
S13	4981,028	4697,633	4783,812	5285,00	303,97	587,37	501,19
S14	4982,907	4601,662	4764,94	5450,00	467,09	848,34	685,06
S15	5009,33	4597,609	4604,357	5367,50	358,17	769,89	763,14
S16	5011,548	4606,611	4703,541	5331,00	319,45	724,39	627,46
S17	5017,651	4490,712	4685,259	5450,00	432,35	959,29	764,74
S18	5026,842	4404,794	4682,933	5395,00	368,16	990,21	712,07
S19	5040,303	4418,386	4603,318	5600,19	559,89	1181,80	996,87
S20	5079,31	4367,268	4347,678	5440,00	360,69	1072,73	1092,32
S21	5081,502	4437,013	4463,751	5670,00	588,50	1232,99	1206,25
S22	5070,235	4491,98	4587,068	5540,00	469,77	1048,02	952,93
S23	5080,89	4485,173	4599,478	5452,96	372,07	967,79	853,48
S24	5089,506	4508,696	4666,389	5347,38	257,87	838,68	680,99
S25	5102,983	4697,816	4590,984	5682,00	579,02	984,18	1091,02
S26	5108,193	4721,347	4580,325	5375,00	266,81	653,65	794,68
S27	5114,841	4738,807	4671,807	5275,00	160,16	536,19	603,19
S28	5135,35	4864,16	4574,216	5455,64	320,29	591,48	881,42
S29	5137,455	5002,414	4537,8	5211,45	74,00	209,04	673,65
S30	5142,879	5061,237	4634,664	5384,00	241,12	322,76	749,34
S31	5161,592	5080,172	4579,306	5159,22	-2,37	79,05	579,91
S32	5177,87	5177,172	4470,953	4790,10	-387,77	-387,07	319,15
S33	5169,026	5320,728	4637,675	4938,50	-230,53	-382,23	300,83
S34	5187,906	5294,771	4561,37	5051,67	-136,24	-243,10	490,30
S35	5212,864	5283,515	4426,499	4906,10	-306,76	-377,41	479,60
S36	5198,088	5222,274	4629,929	4971,11	-226,98	-251,16	341,18
S37	5198,633	5113,231	4713,337	4850,00	-348,63	-263,23	136,66
S38	5209,838	5006,569	4730,493	4900,00	-309,84	-106,57	169,51
S39	5214,73	5072,696	4721,005	5026,62	-188,11	-46,08	305,62
SEMANA	ARIMA	HW	RNA	P. REAL	DIF AR	DIF HW	DIF RN

S40	5224,463	4837,246	4737,705	5050,08	-174,38	212,83	312,38
S41	5238,725	4819,21	4698,346	4999,00	-239,73	179,79	300,65
S42	5245,664	4863,47	4712,554	4967,50	-278,16	104,03	254,95
S43	5243,374	4981,343	4765,059	5098,02	-145,35	116,68	332,96
S44	5246,311	4942,91	4802,152	4950,00	-296,31	7,09	147,85
S45	5262,396	4920,015	4804,941	4988,00	-274,40	67,98	183,06
S46	5269,832	4821,791	4900,431	4982,61	-287,22	160,82	82,18
S47	5283,485	4796,733	4786,85	4940,00	-343,49	143,27	153,15
S48	5294,335	4993,563	4722,561	4680,00	-614,34	-313,56	-42,56
S49	5310,651	5053,773	4710,897	4634,00	-676,65	-419,77	-76,90
S50	5309,493	5114,484	4793,941	4759,00	-550,49	-355,48	-34,94
S51	5306,477	5089,198	4877,666	4709,00	-597,48	-380,20	-168,67
S52	5322,285	4984,226	4733,327	4737,00	-585,29	-247,23	3,67

DIF T: 5169,70 20410,10 30029,27

Acá podemos darnos cuenta que claramente que la metodología con un mayor ajuste fue con el modelo Box-Jenkins ya que el valor real menos el valor pronosticado dio en suma total del año un valor menor que los modelos HW y RNA.

Modelo Arima completo para la acción Falabella:

Modelo ARIMA

Series: fala.ts2

ARIMA(0,1,1)(0,0,1)[52] with drift

Coefficients:

ma1 sma1 drift

-0.1446 -0.0841 8.2557

s.e. 0.0456 0.0470 4.1626

sigma^2 estimated as 12933: log likelihood=-2873.02

AIC=5754.04 AICc=5754.12 BIC=5770.63

Training set error measures:

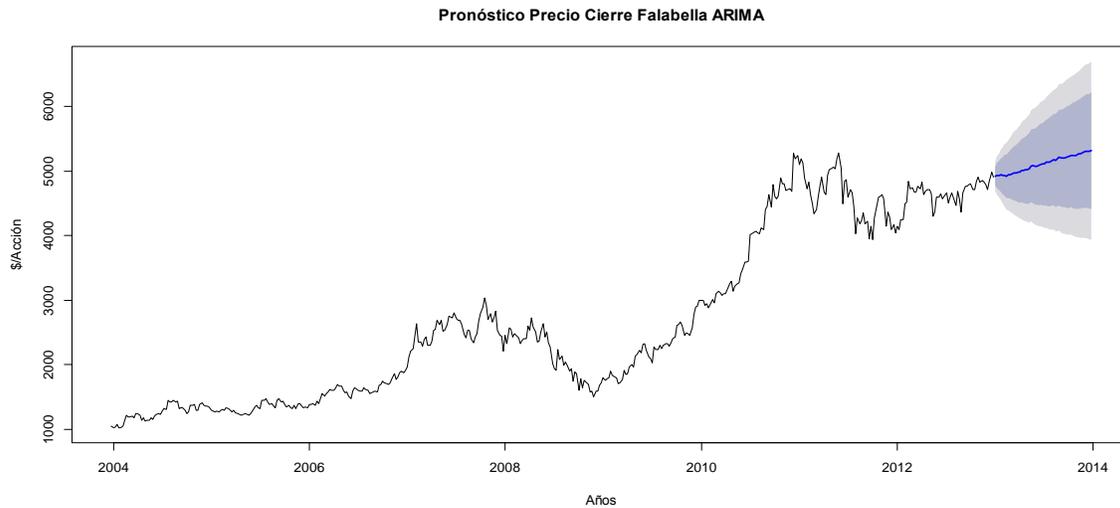
ME RMSE MAE MPE MAPE MASE

Training set -0.0399142 113.4828 77.79994 -0.166659 2.956228 0.1135741

ACF1

Training set -0.002095633

GRÁFICO DE LA SERIE CON MODELO ARIMA

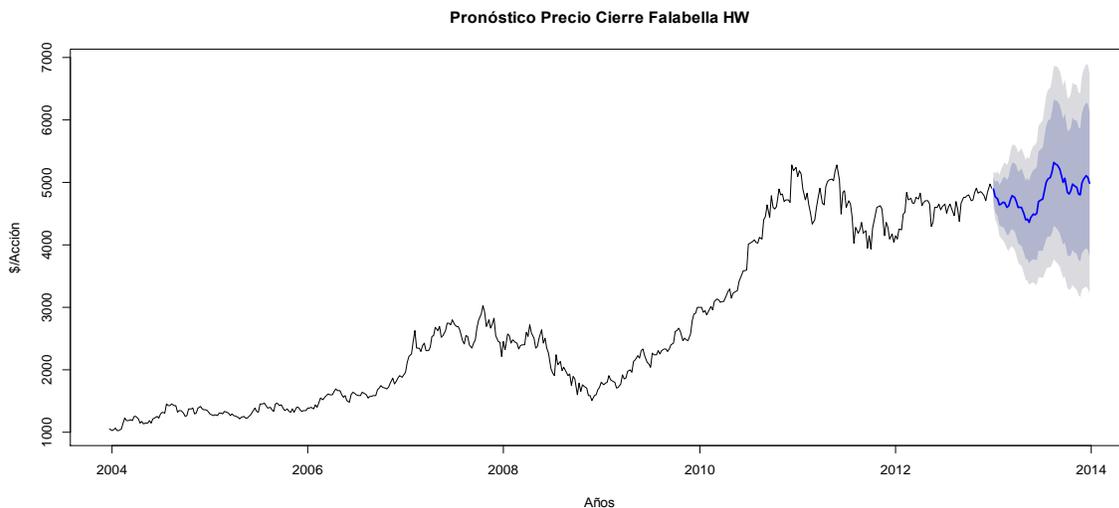


Accuracy Holt-Winters Falabella

accuracy(forfalahw,fala.ts3)

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	7.109779	145.3670	102.9760	0.1727829	3.627206	0.1503268
Test set	396.982734	635.3927	529.7267	7.1356814	9.896703	0.7733070
ACF1 Theil's U						
Training set	0.09681242	NA				
Test set	0.89515233	3.820993				

GRÁFICO DE LA SERIE CON EL MODELO HOLT- WINTERS:

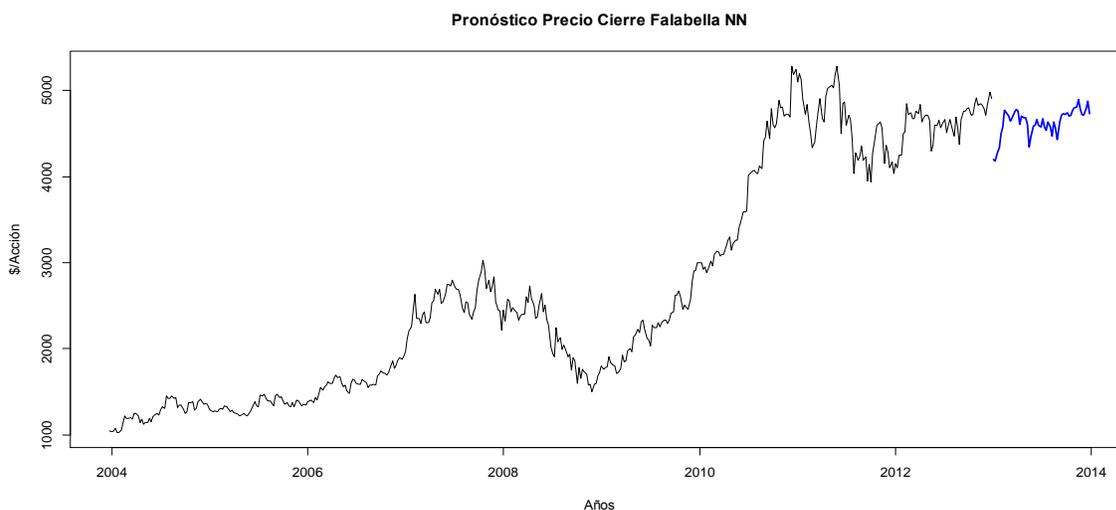


ACCURACY MODELO DE REDES NEURONALES FALABELLA

> accuracy(fornnfal,fala.ts3)

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	0.09004858	111.7649	79.55183	-0.1619711	2.888013	0.1161316
Test set	581.96664247	682.4103	594.80631	10.8462234	11.120138	0.8683117
ACF1 Theil's U						
Training set	0.001358667	NA				
Test set	0.803965055	4.081217				

GRÁFICO DE LA SERIE CON REDES NEURONALES:



4.1 RESULTADOS PARA LA ACCION LAN

PRONOSTICOS DE LA ACCIÓN LAN AÑO 2013

	ARIMA	HW	RNA	P, REAL	DIF AR	DIF HW	DIF RN
S1	11264,62	11320,9	11981,09	11416,60	151,98	95,70	-564,49
S2	11264,62	11088,68	12256,89	11850,00	585,38	761,32	-406,89
S3	11264,62	10998,29	12263,76	11690,00	425,38	691,71	-573,76
S4	11264,62	11436,88	11811,61	11670,00	405,38	233,12	-141,61
S5	11264,62	11762,14	12244,84	11460,00	195,38	-302,14	-784,84
S6	11264,62	12186,35	12222,37	11584,50	319,88	-601,85	-637,87
S7	11264,62	12160,29	13151	11306,00	41,38	-854,29	-1845,00
S8	11264,62	11790,56	12813,22	11263,44	-1,18	-527,12	-1549,78
S9	11264,62	11633,6	12732,61	11360,00	95,38	-273,60	-1372,61
S10	11264,62	11727,27	12832,56	10870,00	-394,62	-857,27	-1962,56
S11	11264,62	11719,23	13284,35	10588,14	-676,48	-1131,09	-2696,21
S12	11264,62	12022,94	13471,83	10402,00	-862,62	-1620,94	-3069,83
S13	11264,62	12187,97	13937,52	9620,00	-1644,62	-2567,97	-4317,52

	ARIMA	HW	RNA	P, REAL	DIF AR	DIF HW	DIF RN
S14	11264,62	12231,31	13618,23	9740,00	-1524,62	-2491,31	-3878,23
S15	11264,62	12449,59	13223,54	10090,00	-1174,62	-2359,59	-3133,54
S16	11264,62	12575,08	13303,5	10103,00	-1161,62	-2472,08	-3200,50
S17	11264,62	12465,56	13394,88	9710,00	-1554,62	-2755,56	-3684,88
S18	11264,62	12308,89	13178,28	9701,00	-1563,62	-2607,89	-3477,28
S19	11264,62	12088,79	12977,47	9229,00	-2035,62	-2859,79	-3748,47
S20	11264,62	11687,74	12089,1	9046,29	-2218,33	-2641,45	-3042,81
S21	11264,62	11930,05	12011,3	8900,00	-2364,62	-3030,05	-3111,30
S22	11264,62	12226,21	12366,54	9020,00	-2244,62	-3206,21	-3346,54
S23	11264,62	12116,31	12357,23	8520,00	-2744,62	-3596,31	-3837,23
S24	11264,62	12168,15	12693,65	7981,61	-3283,01	-4186,54	-4712,04
S25	11264,62	12192,4	13158,74	8630,00	-2634,62	-3562,40	-4528,74
S26	11264,62	11573,12	12763,2	8049,00	-3215,62	-3524,12	-4714,20
S27	11264,62	11064,46	12376,87	7490,00	-3774,62	-3574,46	-4886,87
S28	11264,62	10863,04	12301,7	7489,00	-3775,62	-3374,04	-4812,70
S29	11264,62	10759,84	12180,66	7338,00	-3926,62	-3421,84	-4842,66
S30	11264,62	10538,12	11875,28	6854,15	-4410,47	-3683,97	-5021,13
S31	11264,62	10555,97	11525,2	6250,00	-5014,62	-4305,97	-5275,20
S32	11264,62	10755,64	11276,58	6350,00	-4914,62	-4405,64	-4926,58
S33	11264,62	10836,74	11405,93	6462,90	-4801,72	-4373,84	-4943,03
S34	11264,62	11066,01	11584,89	6410,42	-4854,20	-4655,59	-5174,47
S35	11264,62	11327,6	11278,27	7066,60	-4198,02	-4261,00	-4211,67
S36	11264,62	11459,15	11281,19	7301,00	-3963,62	-4158,15	-3980,19
S37	11264,62	11597,22	11717,87	7415,00	-3849,62	-4182,22	-4302,87
S38	11264,62	11455,25	11898,37	7754,00	-3510,62	-3701,25	-4144,37
S39	11264,62	11421,48	11840,4	7575,00	-3689,62	-3846,48	-4265,40
S40	11264,62	11141,8	12222,04	7548,00	-3716,62	-3593,80	-4674,04
S41	11264,62	10982,77	11900,52	7816,58	-3448,04	-3166,19	-4083,94
S42	11264,62	10944,35	11841	8315,80	-2948,82	-2628,55	-3525,20
S43	11264,62	11089,43	11604,08	8490,00	-2774,62	-2599,43	-3114,08
S44	11264,62	11091,06	11734,21	8410,00	-2854,62	-2681,06	-3324,21
S45	11264,62	11024,96	11631,5	8580,00	-2684,62	-2444,96	-3051,50
S46	11264,62	10956,07	11062,18	8250,00	-3014,62	-2706,07	-2812,18
S47	11264,62	11156,02	10930,04	8540,00	-2724,62	-2616,02	-2390,04
S48	11264,62	11779,67	10893,43	8247,50	-3017,12	-3532,17	-2645,93
S49	11264,62	11857,77	10788,45	8495,00	-2769,62	-3362,77	-2293,45
S50	11264,62	12232,28	11118,62	8330,00	-2934,62	-3902,28	-2788,62
S51	11264,62	12365,87	10926,85	8100,00	-3164,62	-4265,87	-2826,85
S52	11264,62	12672,38	11070,5	8100,00	-3164,62	-4572,38	-2970,50

-
122980,71 140263,72 169626,41

Acá nuevamente podemos darnos cuenta que claramente que la metodología con un mayor ajuste fue con el modelo Box-Jenkins ya que el valor real menos el valor pronosticado dio en suma total del año un valor menor que los modelos HW y RNA.

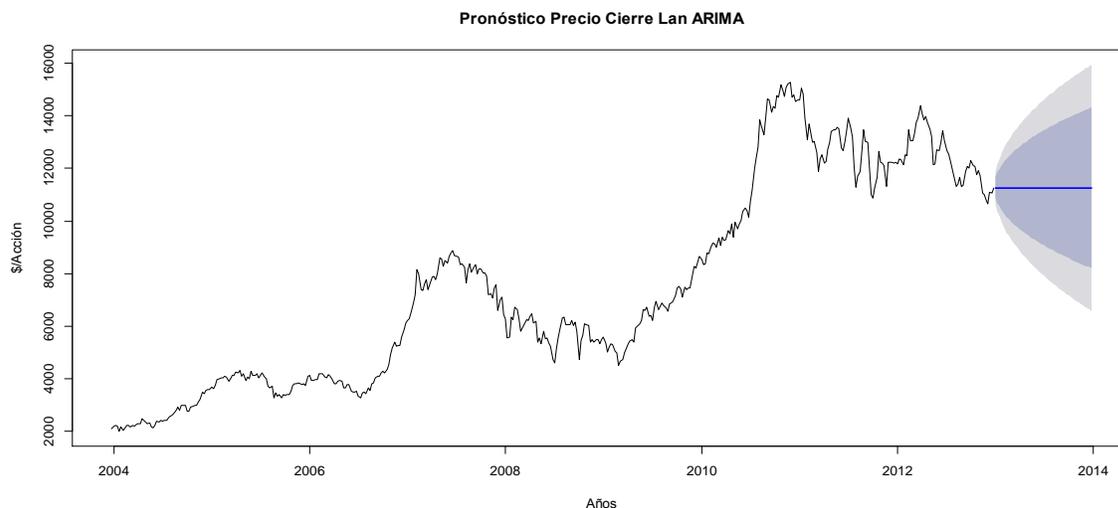
MODELO ARIMA PARA LA ACCION LAN

Series: lan.ts2
 ARIMA(0,1,1)
 Coefficients:
 ma1
 0.0728
 s.e. 0.0460

sigma² estimated as 95483: log likelihood=-3347.28
 AIC=6698.55 AICc=6698.58 BIC=6706.85

Training set error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	18.21806	308.6744	218.5568	0.2557424	3.054745	0.09618351
ACF1						
Training set	-0.003209762					

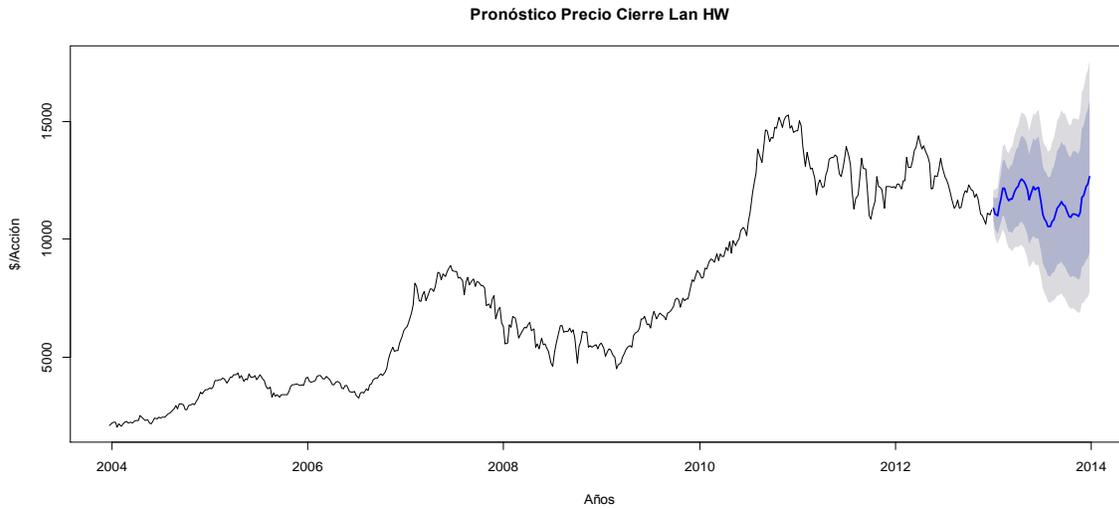


MODELO HOLT-WINTERS PARA LA ACCION LAN

ACCURACY HOLT-WINTERS LAN

> accuracy(forlanhw,lan.ts3)

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1	Theil's U
Training set	-11.30987	398.3817	282.6081	-0.2183789	3.606372	0.1243715	0.2421789	
Test set	-2633.74444	3019.6660	2692.2384	-33.0992652	33.599155	1.1848132		
	0.9138633	9.956197						

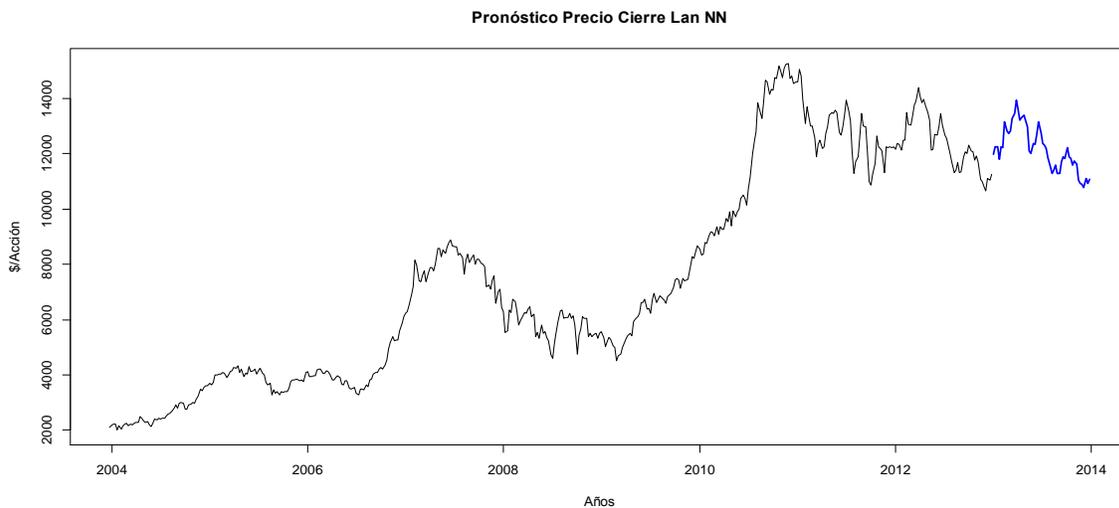


MODELO RNA PARA LA ACCION LAN

ACCURACY MODELO NN LAN

```

> accuracy(fornnlan,lan.ts3)
      ME  RMSE  MAE  MPE  MAPE  MASE
Training set  0.6848712 351.6902 273.0994 -1.322311 3.868808 0.1201869
Test set     -3198.4113226 3477.0642 3198.4113 -39.264163 39.264163 1.4075721
      ACF1 Theil's U
Training set 0.2851097  NA
Test set    0.9138307 11.26102
    
```



4.2 RESULTADOS PARA LA ACCION COPEC

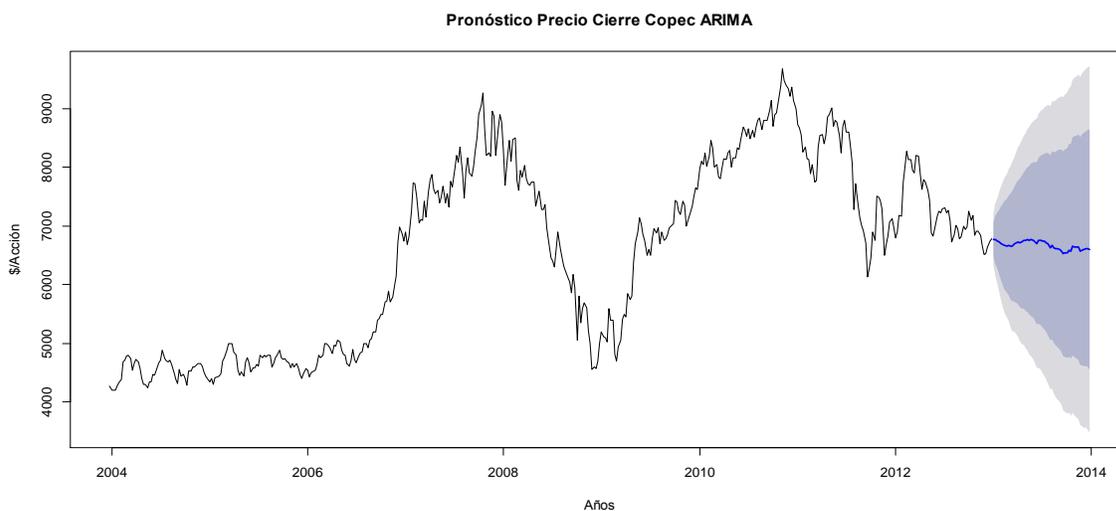
PRONOSTICOS DE LA ACCIÓN COPEC AÑO 2013

	ARIMA	HW	RNA	P. REAL	DIF AR	DIF HW	DIF RN
S1	6770,919	6674,305	6811,16	7134,90	363,98	460,59	323,74
S2	6764,606	6618,643	6896,84	7210,00	445,39	591,36	313,16
S3	6744,452	6632,153	7227,86	7222,20	477,75	590,05	-5,66
S4	6720,377	6683,434	7185,94	7312,20	591,82	628,77	126,26
S5	6704,822	6834,115	7737,19	7330,00	625,18	495,89	-407,19
S6	6681,821	6807,328	7981,94	7404,80	722,98	597,47	-577,14
S7	6672,946	6854,145	8276,42	7368,00	695,05	513,86	-908,42
S8	6659,766	6785,364	8134,99	7260,00	600,23	474,64	-874,99
S9	6673,728	6997,567	8108,68	7148,00	474,27	150,43	-960,68
S10	6650,075	7250,453	7949,90	6800,00	149,93	-450,45	-1149,90
S11	6651,425	7462,813	7913,45	6860,00	208,58	-602,81	-1053,45
S12	6691,474	7660,91	8202,72	6845,00	153,53	-815,91	-1357,72
S13	6710,669	7633,277	8185,06	6800,00	89,33	-833,28	-1385,06
S14	6722,47	7466,469	7891,36	6785,10	62,63	-681,37	-1106,26
S15	6713,333	7365,605	7601,88	6750,00	36,67	-615,61	-851,88
S16	6721,048	7142,161	7753,87	6682,00	-39,05	-460,16	-1071,87
S17	6751,87	6919,949	7750,17	6974,00	222,13	54,05	-776,17
S18	6753,482	6815,177	7613,16	6963,52	210,04	148,34	-649,64
S19	6766,713	6773,197	7441,41	6655,00	-111,71	-118,20	-786,41
S20	6754,273	6827,571	6917,47	6650,00	-104,27	-177,57	-267,47
S21	6763,131	7066,165	6879,69	6620,00	-143,13	-446,17	-259,69
S22	6758,564	7060,039	6998,48	6640,00	-118,56	-420,04	-358,48
S23	6733,521	6963,873	7235,47	6433,23	-300,29	-530,64	-802,24
S24	6705,191	6884,859	7309,29	6049,00	-656,19	-835,86	-1260,29
S25	6750,316	6947,718	7252,24	6649,00	-101,32	-298,72	-603,24
S26	6756,15	7056,665	7300,07	6391,62	-364,53	-665,04	-908,45
S27	6739,101	7191,897	7337,39	6101,00	-638,10	-1090,90	-1236,39
S28	6738,738	7416,553	7271,13	6738,00	-0,74	-678,55	-533,13
S29	6714,605	7483,642	7301,70	6665,00	-49,60	-818,64	-636,70
S30	6693,385	7390,244	7123,85	7003,05	309,66	-387,19	-120,80
S31	6632,491	7217,369	6773,70	6640,00	7,51	-577,37	-133,70
S32	6672,064	7304,064	6880,84	6924,00	251,94	-380,06	43,16
S33	6632,057	7274,445	7033,24	6849,99	217,93	-424,45	-183,25
S34	6615,18	7114,69	6986,15	6785,59	170,41	-329,10	-200,56
S35	6608,606	6959,236	6833,21	6880,00	271,39	-79,24	46,79
S36	6599,427	6852,896	6889,18	7050,00	450,57	197,10	160,82
S37	6574,034	6925,414	7026,98	7050,00	475,97	124,59	23,02

	ARIMA	HW	RNA	P. REAL	DIF AR	DIF HW	DIF RN
S38	6523,251	6951,569	6997,19	7250,00	726,75	298,43	252,81
S39	6536,64	7002,166	7013,47	7050,00	513,36	47,83	36,53
S40	6540,421	6906,468	7308,43	7116,20	575,78	209,73	-192,23
S41	6585,821	6885,675	7142,03	7262,47	676,65	376,80	120,44
S42	6571,535	6867,248	7215,57	7536,76	965,22	669,51	321,19
S43	6651,543	6991,015	6869,84	7413,33	761,79	422,32	543,49
S44	6647,947	7082,056	6940,95	7565,00	917,05	482,94	624,05
S45	6644,498	7107,522	6951,82	7407,77	763,27	300,25	455,95
S46	6636,543	7043,065	6883,97	7450,00	813,46	406,94	566,03
S47	6569,149	7062,587	6681,89	7310,00	740,85	247,41	628,11
S48	6588,394	7149,11	6528,64	7297,00	708,61	147,89	768,36
S49	6599,578	7168,583	6543,55	7170,00	570,42	1,42	626,45
S50	6617,742	7182,702	6610,49	7061,00	443,26	-121,70	450,51
S51	6617,058	7058,567	6701,37	6982,00	364,94	-76,57	280,63
S52	6600,48	6929,251	6734,68	7011,50	411,02	82,25	276,82
					15609,80	-4194,76	-14630,71

Acá logramos un cambio pero aún no el de lo esperado donde nos da como resultado que el mejor modelo en cuanto al ajuste con menor imprecisión fue el modelo Holt-winters a través de su análisis de suavisamiento exponencial.

GRAFICO CON EL MODELO ARIMA



SUMMARY(ARCOPEC)

Series: copec.ts2
 ARIMA(0,1,0)(0,0,2)[52]

Coefficients:

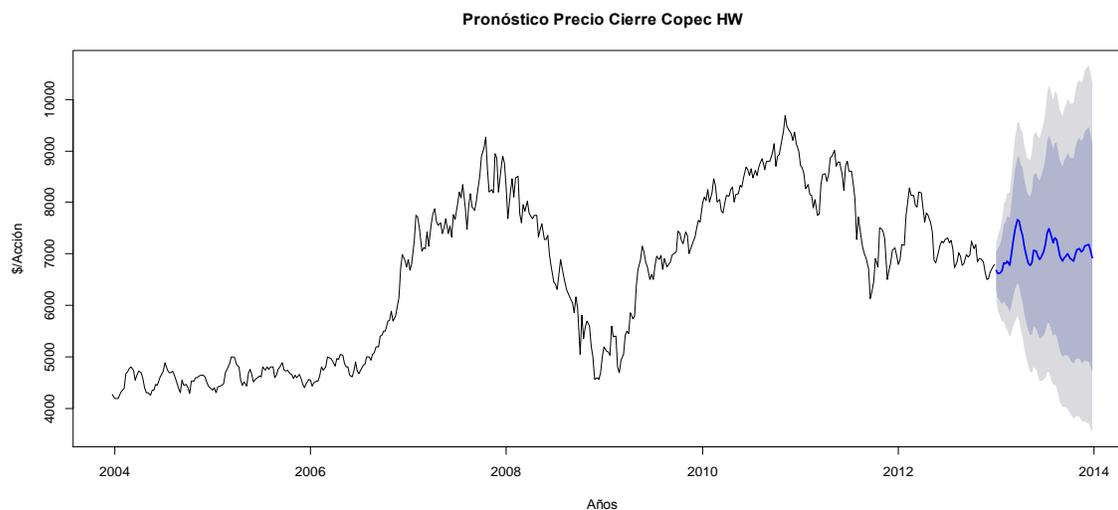
sma1 sma2
 -0.0305 0.0921
 s.e. 0.0455 0.0538

sigma² estimated as 48737: log likelihood=-3190.37
 AIC=6386.74 AICc=6386.79 BIC=6399.18

Training set error measures:

ME RMSE MAE MPE MAPE MASE
 Training set 4.612463 220.5296 160.1959 0.02878542 2.409977 0.1207392
 ACF1
 Training set -0.005637729

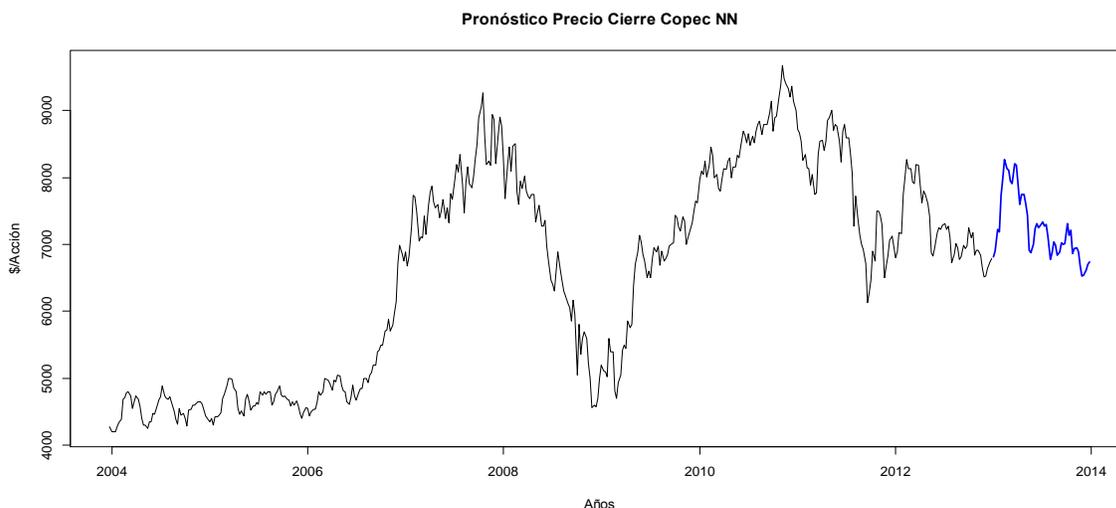
GRAFICO CON EL MODELO HOLT-WINTERS



ACCURACY HW COPEC

```
> accuracy(forcopechw,copec.ts3)
ME RMSE MAE MPE MAPE MASE
Training set 1.782065 277.7971 206.0983 -0.02005387 2.991751 0.1553357
Test set -79.928082 482.6970 405.0253 -1.44685941 5.908455 0.3052664
ACF1 Theil's U
Training set 0.1660776 NA
Test set 0.8583496 2.276614
```

GRAFICO CON EL MODELO RNA



ACCURACY NN COPEC

```
> accuracy(formncopec,copec.ts3)
```

```
ME RMSE MAE MPE MAPE MASE ACF1 Theil's U
Training set 1.777729e-03 221.5908 164.0991 -0.1078455 2.409679 0.123681 -
```

4.3 RESULTADOS PARA LA ACCION CHILE

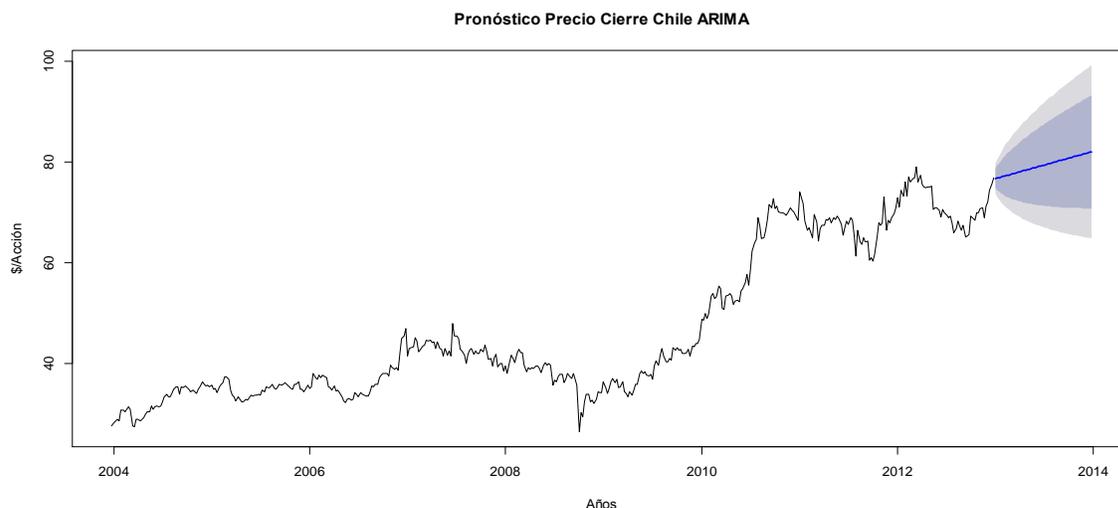
PRONOSTICOS DE LA ACCIÓN CHILE AÑO 2013

	ARIMA	HW	RNA	P. REAL	DIF AR	DIF HW	DIF RN
S1	76,70279	77,20988	71,99366	77,90	1,20	0,69	5,91
S2	76,80707	75,19385	71,92359	77,50	0,69	2,31	5,58
S3	76,91135	75,69366	73,60859	77,00	0,09	1,31	3,39
S4	77,01563	74,05881	73,16331	77,87	0,85	3,81	4,71
S5	77,11991	75,43911	75,1395	79,28	2,16	3,84	4,14
S6	77,2242	76,44273	73,74298	80,15	2,93	3,71	6,41
S7	77,32848	77,19586	75,93997	78,00	0,67	0,80	2,06
S8	77,43276	78,82165	75,81254	78,31	0,88	-0,51	2,50
S9	77,53704	79,91103	75,96518	78,00	0,46	-1,91	2,03
S10	77,64132	79,59472	76,55152	78,30	0,66	-1,29	1,75
S11	77,7456	76,11665	77,51888	73,85	-3,90	-2,27	-3,67
S12	77,84988	72,85784	75,58754	73,98	-3,87	1,12	-1,61
S13	77,95416	72,14906	76,85327	71,45	-6,50	-0,70	-5,40
S14	78,05844	70,76311	75,29082	73,25	-4,81	2,49	-2,04
S15	78,16272	71,22645	74,19515	73,00	-5,16	1,77	-1,20
S16	78,267	70,74857	74,58764	72,71	-5,56	1,96	-1,88
S17	78,37128	70,32624	74,88653	73,20	-5,17	2,87	-1,69
S18	78,47556	69,60672	74,67503	73,51	-4,97	3,90	-1,17

	ARIMA	HW	RNA	P. REAL	DIF AR	DIF HW	DIF RN
S19	78,57984	70,2678	74,00624	73,38	-5,20	3,11	-0,63
S20	78,68412	69,94768	70,94577	73,80	-4,88	3,85	2,85
S21	78,7884	71,28906	71,16114	73,36	-5,43	2,07	2,20
S22	78,89268	72,01896	70,93023	72,30	-6,59	0,28	1,37
S23	78,99696	72,04112	70,4749	69,90	-9,10	-2,14	-0,57
S24	79,10124	72,06458	70,00943	69,85	-9,25	-2,21	-0,16
S25	79,20552	73,57032	70,62503	73,00	-6,21	-0,57	2,37
S26	79,3098	72,80287	69,71271	70,75	-8,56	-2,05	1,04
S27	79,41408	74,06779	69,60592	69,70	-9,71	-4,37	0,09
S28	79,51836	76,57956	69,55148	73,48	-6,04	-3,10	3,93
S29	79,62264	77,47614	69,22581	73,10	-6,52	-4,38	3,87
S30	79,72693	76,83019	68,09168	74,00	-5,73	-2,83	5,91
S31	79,83121	76,6409	66,78402	74,24	-5,59	-2,40	7,46
S32	79,93549	77,49077	67,25168	73,25	-6,69	-4,24	6,00
S33	80,03977	78,51754	67,95708	72,04	-8,00	-6,48	4,08
S34	80,14405	79,64474	67,3297	72,19	-7,95	-7,45	4,86
S35	80,24833	80,087	67,32838	74,33	-5,92	-5,76	7,00
S36	80,35261	78,41288	67,15882	76,00	-4,35	-2,41	8,84
S37	80,45689	79,13685	65,50679	76,50	-3,96	-2,64	10,99
S38	80,56117	78,91617	65,83456	76,22	-4,34	-2,70	10,39
S39	80,66545	79,3529	66,66658	77,57	-3,10	-1,78	10,90
S40	80,76973	77,88068	69,64855	76,72	-4,05	-1,16	7,07
S41	80,87401	78,44706	68,76051	77,25	-3,62	-1,20	8,49
S42	80,97829	77,66923	68,52224	77,02	-3,96	-0,65	8,50
S43	81,08257	77,8275	69,91154	77,00	-4,08	-0,83	7,09
S44	81,18685	77,17472	69,89666	75,92	-5,27	-1,25	6,02
S45	81,29113	76,46456	70,66699	75,00	-6,29	-1,46	4,33
S46	81,39541	76,99697	71,17702	77,67	-3,73	0,67	6,49
S47	81,49969	77,2521	70,01048	77,30	-4,20	0,05	7,29
S48	81,60397	79,65758	70,78532	77,35	-4,25	-2,31	6,56
S49	81,70825	79,78112	72,25413	74,74	-6,97	-5,04	2,49
S50	81,81253	80,00769	74,17291	75,20	-6,61	-4,81	1,03
S51	81,91681	79,46166	75,47968	74,48	-7,44	-4,98	-1,00
S52	82,02109	79,18214	75,42876	74,75	-7,27	-4,43	-0,68
					-230,20	-51,69	176,31

En esta serie de tiempo nuevamente el modelo de suaviamiento exponencial lideró en los ajuste a los valores reales de la serie de tiempo.

GRAFICO PARA EL MODELO ARIMA:



Summary(forarchile)

Forecast method: ARIMA(0,1,1) with drift

Model Information:

Series: chile.ts2

ARIMA(0,1,1) with drift

Coefficients:

ma1 drift

-0.1850 0.1043

s.e. 0.0459 0.0558

sigma^2 estimated as 2.196: log likelihood=-845.81

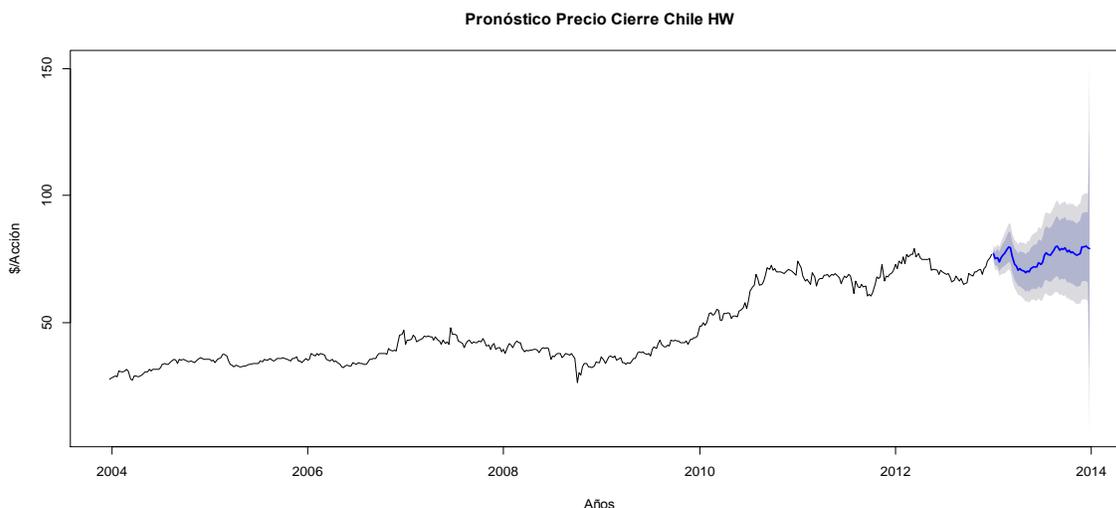
AIC=1697.62 AICc=1697.67 BIC=1710.07

Error measures:

ME RMSE MAE MPE MAPE MASE

Training set 0.0003064195 1.478629 0.9933228 -0.09322959 2.144783 0.1349236

GRAFICO DE LA SERIE CON EL MODELO WH:



ACCURACY(FORCHILEHW,CHILE.TS3)

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	0.05914846	1.707113	1.169732	0.03552747	2.413087	0.1588854

GRAFICO DE MODELO RNA



ACCURACY RNA CHILE

Model Information:

Average of 20 networks, each of which is a 9-5-1 network with 56 weights
options were - linear output units

Error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	0.007714575	1.497424	1.017893	-0.08617224	2.131338	0.138261	

4.4 RESULTADOS PARA LA ACCIÓN CCU

PRONOSTICOS DE LA ACCIÓN CCU AÑO 2013

	ARIMA	HW	RNA	P. REAL	DIF AR	DIF HW	DIF RN
S1	7553,497	7562,883	6320,235	7540,00	-13,50	-22,88	1219,77
S2	7613,109	7470,665	6209,319	7590,00	-23,11	119,34	1380,68
S3	7615,813	7466,804	6522,527	7640,00	24,19	173,20	1117,47
S4	7628,966	7448,914	6463,698	7595,00	-33,97	146,09	1131,30
S5	7634,685	7439,086	6484,732	7430,00	-204,69	-9,09	945,27
S6	7638,547	7411,41	6790,381	7430,00	-208,55	18,59	639,62
S7	7625,565	7540,601	6807,043	7430,00	-195,57	-110,60	622,96
S8	7654,143	7597,711	6753,103	7745,00	90,86	147,29	991,90
S9	7663,898	7676,961	6899,139	7770,00	106,10	93,04	870,86
S10	7645,849	7807,01	6963,083	7770,00	124,15	-37,01	806,92
S11	7584,118	7818,794	7403,439	7960,00	375,88	141,21	556,56
S12	7632,696	7764,864	7140,835	7960,00	327,30	195,14	819,17
S13	7649,446	7807,58	7088,196	7800,00	150,55	-7,58	711,80
S14	7655,805	7693,87	6984,802	7505,00	-150,81	-188,87	520,20
S15	7689,221	7768,602	6936,826	7321,77	-367,45	-446,83	384,94
S16	7719,859	7675,038	6645,673	7321,77	-398,09	-353,27	676,10
S17	7715,013	7597,88	6689,176	8190,00	474,99	592,12	1500,82
S18	7726,168	7656,735	6661,304	7850,00	123,83	193,27	1188,70
S19	7752,419	7597,087	6671,213	7937,40	184,98	340,31	1266,19
S20	7776,161	7551,853	6679,958	7370,00	-406,16	-181,85	690,04
S21	7773,306	7683,335	6562,029	6710,00	-1063,31	-973,34	147,97
S22	7803,033	7704,006	6513,297	6840,00	-963,03	-864,01	326,70
S23	7840,72	7726,901	6307,414	6718,79	-1121,93	-1008,11	411,38
S24	7846,798	7770,485	6301,522	6625,00	-1221,80	-1145,49	323,48
S25	7855,596	7822,929	6417,574	7275,00	-580,60	-547,93	857,43
S26	7860,324	7839,506	6342,811	7035,00	-825,32	-804,51	692,19
S27	7870,669	7860,612	6334,963	7200,00	-670,67	-660,61	865,04
S28	7887,299	7931,287	6362,938	7200,00	-687,30	-731,29	837,06
S29	7957,581	7845,845	6359,638	7262,47	-695,11	-583,37	902,83
S30	7965,22	7824,146	6229,129	7020,00	-945,22	-804,15	790,87
S31	7975,061	7764,052	6294,928	7199,70	-775,36	-564,35	904,77
S32	7980,355	7948,319	6254,467	7598,00	-382,36	-350,32	1343,53
S33	7982,111	8161,736	6376,463	6748,00	-1234,11	-1413,74	371,54
S34	7979,027	8364,658	6363,903	6830,00	-1149,03	-1534,66	466,10
S35	8016,331	8184,765	6330,393	6830,00	-1186,33	-1354,77	499,61
S36	7997,178	8256,861	6416,186	6700,00	-1297,18	-1556,86	283,81

	ARIMA	HW	RNA	P. REAL	DIF AR	DIF HW	DIF RN
S37	7991,272	8459,295	6561,877	0,00	-7991,27	-8459,30	-6561,88
S38	8017,476	8348,636	6580,122	6736,20	-1281,28	-1612,44	156,08
S39	8015,824	8250,46	6596,178	6896,00	-1119,82	-1354,46	299,82
S40	8022,751	8199,357	6603,873	6828,00	-1194,75	-1371,36	224,13
S41	7998,214	8239,628	6840,521	6748,00	-1250,21	-1491,63	-92,52
S42	8002,302	8233,048	6965,41	6839,91	-1162,39	-1393,14	-125,50
S43	8015,344	8240,833	6905,388	6839,91	-1175,43	-1400,92	-65,48
S44	8016,55	8287,087	6829,982	6810,00	-1206,55	-1477,09	-19,98
S45	8043,563	8297,104	6696,973	6836,00	-1207,56	-1461,10	139,03
S46	8003,959	8560,343	6943,81	6240,00	-1763,96	-2320,34	-703,81
S47	7990,943	8595,393	7287,361	6500,05	-1490,89	-2095,34	-787,31
S48	7986,339	8485,409	7280,053	6193,77	-1792,57	-2291,64	-1086,28
S49	7983,328	8494,044	7242,144	6212,00	-1771,33	-2282,04	-1030,14
S50	7941,662	8428,665	7468,744	6212,00	-1729,66	-2216,67	-1256,74
S51	8009,879	8245,378	7290,545	6149,50	-1860,38	-2095,88	-1141,05
S52	8016,556	8121,262	7167,175	6250,00	-1766,56	-1871,26	-917,18
					-44582,31	-49290,49	15096,75

Nuevamente nos da como resultado que el mejor modelo en cuanto al ajuste con menor imprecisión fue el modelo Holt-winters a través de su análisis de suavizado exponencial.

GRAFICO MODELO ARIMA PARA CCU



RESUMEN MODELO ARIMA PARA LA ACCION CCU

Forecast method: ARIMA(0,1,2)(0,0,2)[52] with drift

Model Information:

Series: ccu.ts2

ARIMA(0,1,2)(0,0,2)[52] with drift

Coefficients:

```

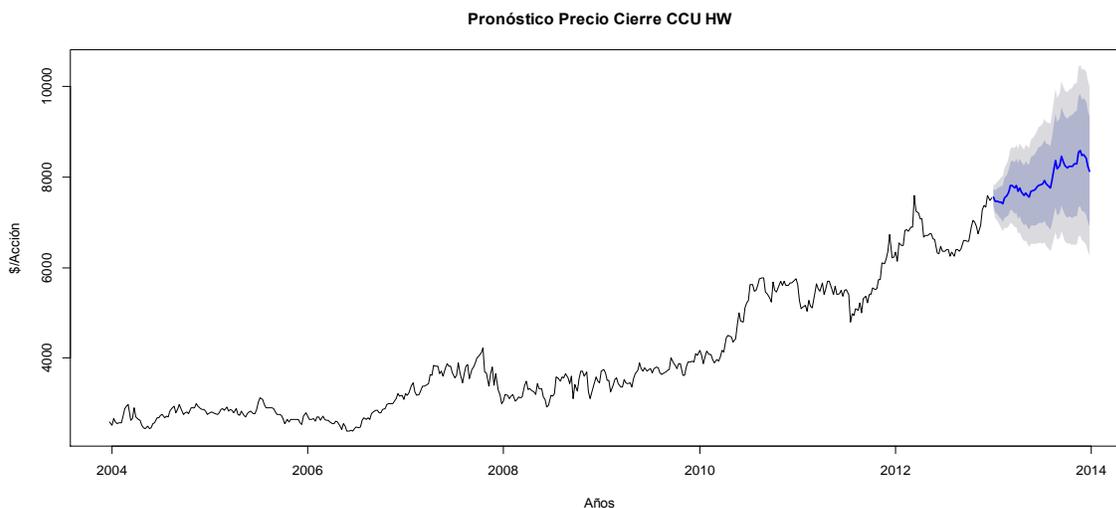
mal   ma2   sma1   sma2   drift
-0.1594 -0.0714 -0.0779 -0.0910 10.5397
s.e. 0.0462 0.0464 0.0508 0.0541 4.2776
sigma^2 estimated as 19458: log likelihood=-2968.84
AIC=5949.67 AICc=5949.85 BIC=5974.56
    
```

Error measures:

```

ME   RMSE   MAE   MPE   MAPE   MASE
Training set -0.4209244 139.1941 99.31262 -0.174244 2.537716 0.1492304
    
```

GRAFICO MODELO HW PARA CCU

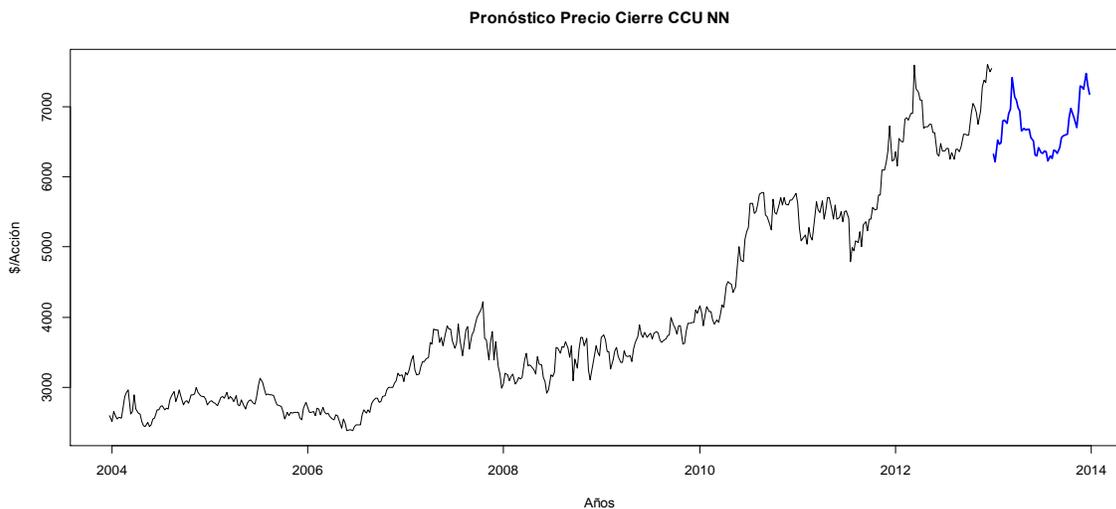


Error measures:

```

ME   RMSE   MAE   MPE   MAPE   MASE
Training set 8.726165 161.3689 118.0867 0.09781971 2.894508 0.1774409
    
```

GRAFICO DEL MODELO RNA PARA LA ACCION CCU



Forecast method: NNAR(8,1)

Model Information:

Average of 20 networks, each of which is
a 9-5-1 network with 56 weights
options were - linear output units

Error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	-0.007584613	157.9109	118.1461	-0.6302065	2.953964	0.1775303

CAPITULO V: CONCLUSIÓN

5 CONCLUSION

Según lo visto en la bibliografía revisada, las arquitecturas de redes neuronales más usadas para el modelamiento de series de tiempo son:

- Redes Lineales
- Perceptron multicapa

Con respecto al desempeño de las arquitecturas de redes neuronales modeladas y respondiendo al mismo tiempo, se puede decir que el desempeño es pobre y que los modelos de redes neuronales usados tradicionalmente para predecir series de tiempo no funcionan bien para predecir los retornos semanales de las cotizaciones bursátiles.

Sin embargo los modelos con el mejor desempeño obtenido fueron:

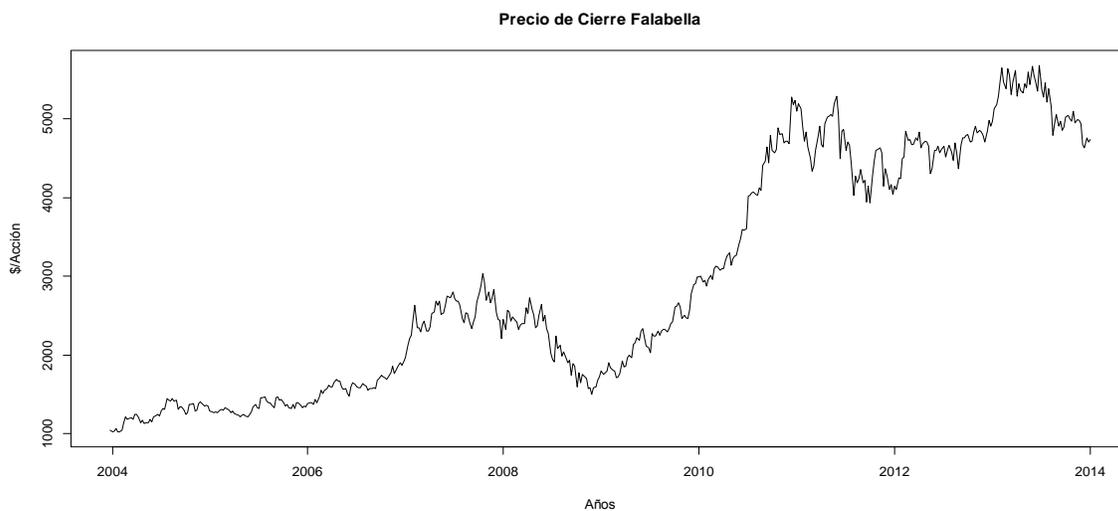
Los Modelos Arima y los Holt-Winters, los cuales se pensaron que tendrían un rendimiento inferior a los de las RNA, pero ocurrió todo lo contrario, siendo estas las con mayor capacidad predictiva en el análisis de las acciones durante el año 2013.

Por otra parte, la muestra, es difícil de determinar una muestra de acciones que sea representativa del mercado bursátil chileno, ya que deberíamos incorporar más acciones, estratificar las acciones por sector económico y considerar otras características más de la muestra. Considerando que el entrenamiento de cada red conlleva un tiempo considerable (sin tomar en cuenta los análisis posteriores) y que se deberían entrenar más de 10 redes por acción, los costos en términos de tiempo serían desproporcionales a los resultados esperados.

6 ANEXOS

6.1 DATOS DE LA ACCION FALABELLA

6.1.1 MODELO ARIMA FALABELLA



Modelo ARIMA

Series: fala.ts2

ARIMA(0,1,1)(0,0,1)[52] with drift

Coefficients:

ma1 sma1 drift

-0.1446 -0.0841 8.2557

s.e. 0.0456 0.0470 4.1626

sigma² estimated as 12933: log likelihood=-2873.02

AIC=5754.04 AICc=5754.12 BIC=5770.63

Training set error measures:

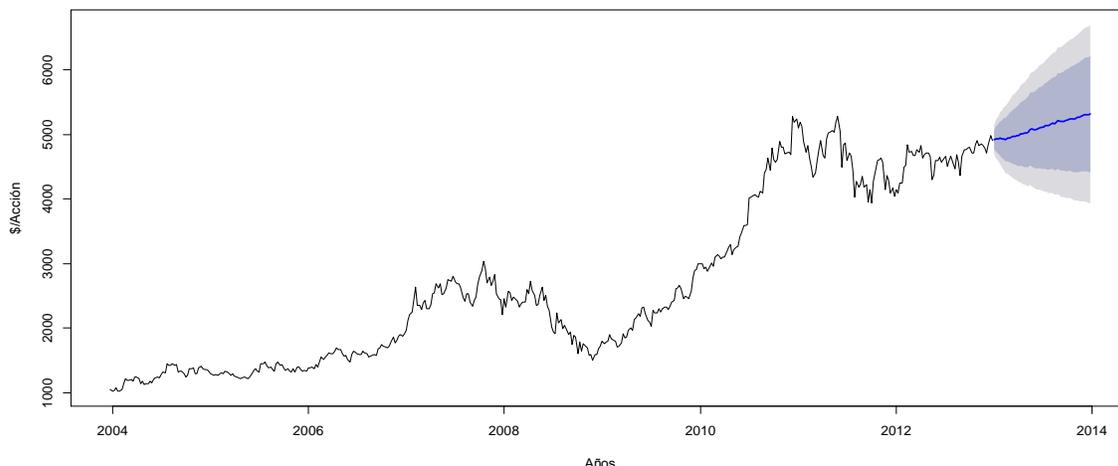
ME RMSE MAE MPE MAPE MASE

Training set -0.0399142 113.4828 77.79994 -0.166659 2.956228 0.1135741

ACF1

Training set -0.002095633

Pronóstico Precio Cierre Falabella ARIMA



Accuracy Modelo ARIMA

> accuracy(forarfala,fala.ts3)

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	-0.0399142	113.4828	77.79994	-0.166659	2.956228	0.1135741
Test set	103.8980139	402.7785	364.51025	1.591823	6.965081	0.5321203

ACF1 Theil's U

Training set	-0.002095633	NA
Test set	0.879304522	2.504025

Pronósticos Modelo ARIMA

> forarfala

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2013.000	4920.540	4774.795	5066.285	4697.642	5143.438
2013.019	4932.928	4741.138	5124.718	4639.610	5226.245
2013.038	4929.824	4701.077	5158.571	4579.985	5279.662
2013.058	4940.906	4680.393	5201.419	4542.485	5339.326
2013.077	4929.740	4640.934	5218.546	4488.050	5371.431
2013.096	4936.219	4621.655	5250.783	4455.134	5417.304
2013.115	4918.980	4580.613	5257.348	4401.492	5436.469
2013.135	4939.337	4578.734	5299.940	4387.843	5490.831
2013.154	4948.009	4566.464	5329.553	4364.487	5531.530
2013.173	4962.528	4561.133	5363.923	4348.647	5576.408
2013.192	4970.243	4549.933	5390.552	4327.435	5613.050
2013.212	4970.326	4531.918	5408.734	4299.839	5640.813
2013.231	4981.028	4525.240	5436.817	4283.960	5678.097
2013.250	4982.907	4510.376	5455.438	4260.234	5705.580
2013.269	5009.330	4520.631	5498.030	4261.929	5756.732
2013.288	5011.548	4507.198	5515.898	4240.212	5782.885
2013.308	5017.651	4498.121	5537.180	4223.099	5812.202
2013.327	5026.842	4492.565	5561.120	4209.735	5843.949
2013.346	5040.303	4491.674	5588.933	4201.247	5879.360

2013.365	5079.310	4516.695	5641.925	4218.864	5939.756
2013.385	5081.502	4505.240	5657.764	4200.185	5962.818
2013.404	5070.235	4480.642	5659.828	4168.530	5971.939
2013.423	5080.890	4478.261	5683.519	4159.249	6002.531
2013.442	5089.506	4474.118	5704.895	4148.351	6030.662
2013.462	5102.983	4475.094	5730.873	4142.710	6063.257
2013.481	5108.193	4468.047	5748.339	4129.174	6087.212
2013.500	5114.841	4462.669	5767.014	4117.430	6112.253
2013.519	5135.350	4471.369	5799.330	4119.879	6150.821
2013.538	5137.455	4461.872	5813.038	4104.240	6170.670
2013.558	5142.879	4455.890	5829.868	4092.220	6193.539
2013.577	5161.592	4463.382	5859.801	4093.773	6229.410
2013.596	5177.870	4468.619	5887.122	4093.164	6262.577
2013.615	5169.026	4448.901	5889.151	4067.690	6270.362
2013.635	5187.906	4457.070	5918.742	4070.189	6305.624
2013.654	5212.864	4471.471	5954.257	4079.002	6346.726
2013.673	5198.088	4446.287	5949.889	4048.308	6347.869
2013.692	5198.633	4436.566	5960.701	4033.152	6364.115
2013.712	5209.838	4437.641	5982.035	4028.864	6390.812
2013.731	5214.730	4432.534	5996.926	4018.464	6410.995
2013.750	5224.463	4432.395	6016.531	4013.099	6435.827
2013.769	5238.725	4436.906	6040.544	4012.448	6465.002
2013.788	5245.664	4434.211	6057.117	4004.654	6486.675
2013.808	5243.374	4422.400	6064.347	3987.803	6498.945
2013.827	5246.311	4415.926	6076.696	3976.347	6516.276
2013.846	5262.396	4422.704	6102.087	3978.199	6546.593
2013.865	5269.832	4420.937	6118.728	3971.559	6568.106
2013.885	5283.485	4425.485	6141.486	3971.287	6595.684
2013.904	5294.335	4427.325	6161.345	3968.357	6620.313
2013.923	5310.651	4434.724	6186.579	3971.036	6650.266
2013.942	5309.493	4424.738	6194.247	3956.377	6662.608
2013.962	5306.477	4412.983	6199.972	3939.996	6672.959
2013.981	5322.285	4420.136	6224.435	3942.567	6702.004

6.1.2 METODO DE HOLT-WINTERS FALABELLA

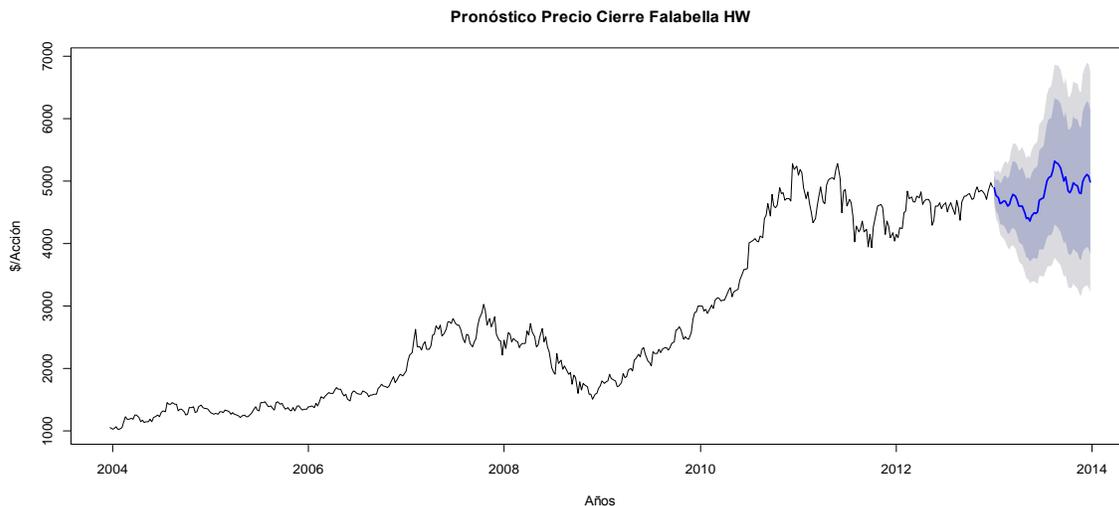
```
> falahw$coefficients
```

	a	b	s1	s2	s3	s4
4771.0028523	1.3875008		1.0261323	1.0009207	0.9925193	0.9709099
	s5	s6	s7	s8	s9	s10
0.9737697	0.9788815	0.9784294		0.9630926	0.9681940	0.9877510
	s11	s12	s13	s14	s15	s16
1.0008222	0.9948951	0.9809131		0.9605953	0.9594712	0.9610715
	s17	s18	s19	s20	s21	s22
0.9366205	0.9184350	0.9210026		0.9100840	0.9243507	0.9355314

```

s23      s24      s25      s26      s27      s28
0.9338439 0.9384704 0.9775528 0.9821656 0.9855133 1.0112908
s29      s30      s31      s32      s33      s34
1.0397348 1.0516577 1.0552878 1.0751274 1.1046210 1.0989157
s35      s36      s37      s38      s39      s40
1.0962638 1.0832453 1.0603215 1.0379046 1.0513107 1.0022259
s41      s42      s43      s44      s45      s46
0.9982020 1.0070801 1.0311918 1.0229421 1.0179115 0.9973035
s47      s48      s49      s50      s51      s52
0.9918362 1.0322391 1.0443859 1.0566291 1.0511039 1.0291283
> falahw$alpha; falahw$betha;falahw$gamma
alpha      betha=0
0.8332549
gamma
0.996057

```



Pronósticos Holt-Winters Falabella

```

> forfalahw
Point Forecast Lo 80 Hi 80 Lo 95 Hi 95
2013.000      4897.104 4710.930 5083.277 4612.376 5181.831
2013.019      4778.173 4538.198 5018.148 4411.163 5145.183
2013.038      4739.444 4455.017 5023.871 4304.450 5174.437
2013.058      4637.602 4318.281 4956.924 4149.242 5125.963
2013.077      4652.613 4296.801 5008.426 4108.445 5196.782
2013.096      4678.396 4288.625 5068.166 4082.293 5274.498
2013.115      4677.592 4258.203 5096.982 4036.192 5318.993
2013.135      4605.608 4164.199 5047.017 3930.531 5280.685
2013.154      4631.347 4161.351 5101.343 3912.550 5350.144
2013.173      4726.268 4222.704 5229.832 3956.134 5496.402
2013.192      4790.200 4257.146 5323.255 3974.963 5605.438
2013.212      4763.213 4210.932 5315.493 3918.573 5607.853

```

2013.231	4697.633	4131.159	5264.106	3831.286	5563.979
2013.250	4601.662	4025.237	5178.088	3720.095	5483.230
2013.269	4597.609	4001.277	5193.940	3685.599	5509.619
2013.288	4606.611	3989.472	5223.749	3662.779	5550.443
2013.308	4490.712	3869.137	5112.286	3540.095	5441.328
2013.327	4404.794	3775.508	5034.080	3442.384	5367.204
2013.346	4418.386	3768.574	5068.198	3424.584	5412.188
2013.365	4367.268	3706.474	5028.063	3356.670	5377.866
2013.385	4437.013	3748.384	5125.642	3383.846	5490.180
2013.404	4491.980	3778.124	5205.837	3400.231	5583.729
2013.423	4485.173	3755.866	5214.481	3369.794	5600.553
2013.442	4508.696	3759.587	5257.805	3363.032	5654.360
2013.462	4697.816	3902.784	5492.848	3481.920	5913.713
2013.481	4721.347	3907.681	5535.012	3476.952	5965.741
2013.500	4738.807	3907.785	5569.829	3467.868	6009.745
2013.519	4864.160	3997.711	5730.609	3539.040	6189.280
2013.538	5002.414	4098.504	5906.325	3620.003	6384.826
2013.558	5061.237	4134.009	5988.466	3643.163	6479.311
2013.577	5080.172	4136.921	6023.423	3637.594	6522.750
2013.596	5177.172	4203.936	6150.407	3688.737	6665.607
2013.615	5320.728	4309.107	6332.349	3773.587	6867.868
2013.635	5294.771	4276.420	6313.122	3737.338	6852.205
2013.654	5283.515	4255.805	6311.225	3711.769	6855.261
2013.673	5222.274	4194.852	6249.697	3650.967	6793.582
2013.692	5113.231	4095.424	6131.039	3556.629	6669.834
2013.712	5006.569	3998.040	6015.099	3464.157	6548.982
2013.731	5072.696	4039.546	6105.846	3492.629	6652.762
2013.750	4837.246	3839.692	5834.800	3311.619	6362.874
2013.769	4819.210	3813.565	5824.855	3281.209	6357.211
2013.788	4863.470	3837.166	5889.773	3293.874	6433.065
2013.808	4981.343	3919.305	6043.381	3357.096	6605.590
2013.827	4942.910	3877.915	6007.906	3314.141	6571.680
2013.846	4920.015	3848.900	5991.129	3281.886	6558.143
2013.865	4821.791	3760.743	5882.839	3199.058	6444.524
2013.885	4796.733	3730.091	5863.376	3165.445	6428.022
2013.904	4993.563	3873.061	6114.064	3279.903	6707.222
2013.923	5053.773	3909.617	6197.929	3303.937	6803.609
2013.942	5114.484	3946.660	6282.309	3328.451	6900.517
2013.962	5089.198	3917.108	6261.289	3296.641	6881.756
2013.981	4984.226	3832.752	6135.700	3223.198	6745.254

Accuracy Holt-Winters Falabella

accuracy(forfalawh,fala.ts3)

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	7.109779	145.3670	102.9760	0.1727829	3.627206	0.1503268
Test set	396.982734	635.3927	529.7267	7.1356814	9.896703	0.7733070

ACF1 Theil's U

Training set 0.09681242 NA
 Test set 0.89515233 3.820993

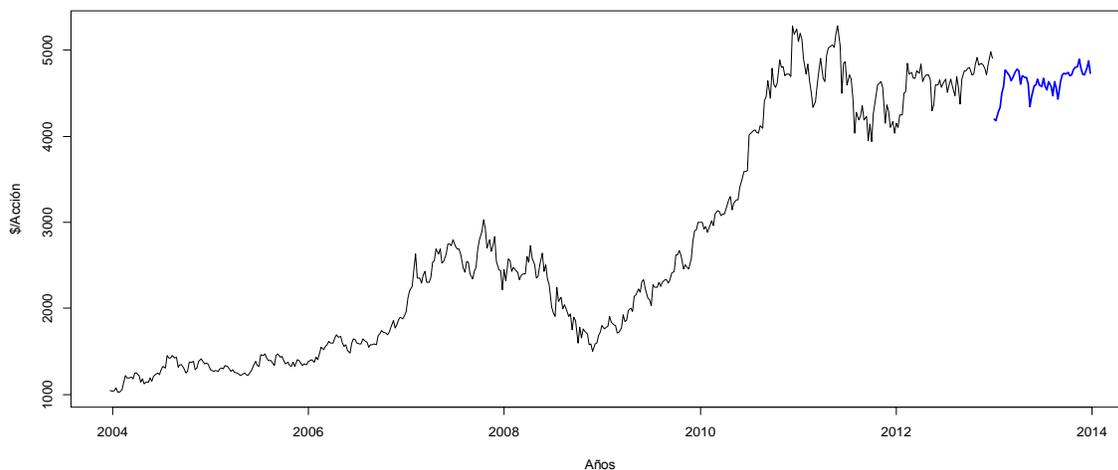
6.1.3 MODELO DE REDES NEURONALES PARA FALABELLA (8 INPUTS, REZAGOS DE LA SERIE DE TIEMPO. EN LA HIDDEN LAYER 5 NODOS)

Series: fala.ts2
 Model: NNAR(8,1)
 Call: nnetar(x = fala.ts2, p = 8, size = 5)

Average of 20 networks, each of which is a 9-5-1 network with 56 weights
 options were - linear output units

sigma² estimated as
 12491

Pronóstico Precio Cierre Falabella NN



Pronóstico con Redes Neuronales
 > fornfal
 Point Forecast

2013	4197.902
2013.01923076923	4176.174
2013.03846153846	4283.637
2013.05769230769	4333.247
2013.07692307692	4498.402
2013.09615384615	4573.562
2013.11538461538	4768.064
2013.13461538462	4728.733
2013.15384615385	4702.048
2013.17307692308	4645.376

2013.19230769231	4686.171
2013.21153846154	4748.170
2013.23076923077	4783.812
2013.25	4764.940
2013.26923076923	4604.357
2013.28846153846	4703.541
2013.30769230769	4685.259
2013.32692307692	4682.933
2013.34615384615	4603.318
2013.36538461538	4347.678
2013.38461538462	4463.751
2013.40384615385	4587.068
2013.42307692308	4599.478
2013.44230769231	4666.389
2013.46153846154	4590.984
2013.48076923077	4580.325
2013.5	4671.807
2013.51923076923	4574.216
2013.53846153846	4537.800
2013.55769230769	4634.664
2013.57692307692	4579.306
2013.59615384615	4470.953
2013.61538461538	4637.675
2013.63461538462	4561.370
2013.65384615385	4426.499
2013.67307692308	4629.929
2013.69230769231	4713.337
2013.71153846154	4730.493
2013.73076923077	4721.005
2013.75	4737.705
2013.76923076923	4698.346
2013.78846153846	4712.554
2013.80769230769	4765.059
2013.82692307692	4802.152
2013.84615384615	4804.941
2013.86538461538	4900.431
2013.88461538462	4786.850
2013.90384615385	4722.561
2013.92307692308	4710.897
2013.94230769231	4793.941
2013.96153846154	4877.666
2013.98076923077	4733.327

Accuracy Modelo de Redes Neuronales Falabella

> accuracy(fornnfal,fala.ts3)

ME RMSE MAE MPE MAPE MASE

Training set 0.09004858 111.7649 79.55183 -0.1619711 2.888013 0.1161316

```
Test set 581.96664247 682.4103 594.80631 10.8462234 11.120138 0.8683117
          ACF1 Theil's U
Training set 0.001358667 NA
Test set 0.803965055 4.081217
```

6.2 MODELOS PARA LAN ARIMA

```
> summary(arlan)
Series: lan.ts2
ARIMA(0,1,1)
```

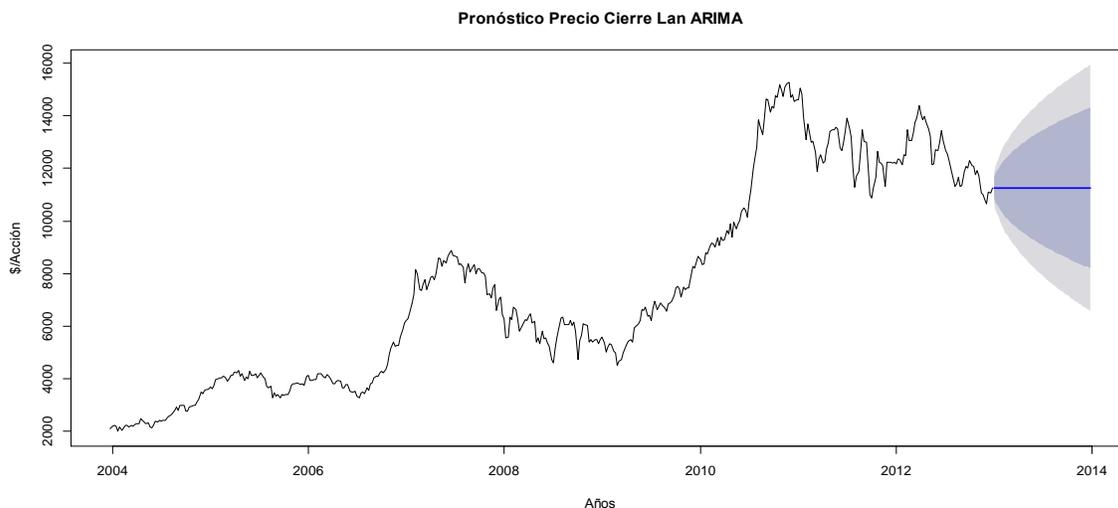
Coefficients:

```
ma1
0.0728
s.e. 0.0460
```

```
sigma^2 estimated as 95483: log likelihood=-3347.28
AIC=6698.55 AICc=6698.58 BIC=6706.85
```

Training set error measures:

```
ME RMSE MAE MPE MAPE MASE
Training set 18.21806 308.6744 218.5568 0.2557424 3.054745 0.09618351
          ACF1
Training set -0.003209762
```



Pronósticos Lan ARIMA

> forarlan

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2013.000	11264.62	10868.616	11660.63	10658.984	11870.26
2013.019	11264.62	10683.831	11845.41	10376.380	12152.86
2013.038	11264.62	10545.028	11984.21	10164.099	12365.14
2013.058	11264.62	10428.971	12100.27	9986.605	12542.64
2013.077	11264.62	10327.174	12202.07	9830.919	12698.32
2013.096	11264.62	10235.396	12293.85	9690.557	12838.68
2013.115	11264.62	10151.157	12378.08	9561.726	12967.52
2013.135	11264.62	10072.858	12456.38	9441.978	13087.26
2013.154	11264.62	9999.396	12529.85	9329.626	13199.62
2013.173	11264.62	9929.971	12599.27	9223.449	13305.79
2013.192	11264.62	9863.982	12665.26	9122.529	13406.71
2013.212	11264.62	9800.966	12728.28	9026.154	13503.09
2013.231	11264.62	9740.553	12788.69	8933.761	13595.48
2013.250	11264.62	9682.446	12846.80	8844.893	13684.35
2013.269	11264.62	9626.398	12902.84	8759.175	13770.07
2013.288	11264.62	9572.205	12957.04	8676.294	13852.95
2013.308	11264.62	9519.694	13009.55	8595.986	13933.26
2013.327	11264.62	9468.718	13060.52	8518.025	14011.22
2013.346	11264.62	9419.150	13110.09	8442.217	14087.02
2013.365	11264.62	9370.879	13158.36	8368.392	14160.85
2013.385	11264.62	9323.807	13205.43	8296.403	14232.84
2013.404	11264.62	9277.851	13251.39	8226.119	14303.12
2013.423	11264.62	9232.934	13296.31	8157.425	14371.82
2013.442	11264.62	9188.989	13340.25	8090.216	14439.03
2013.462	11264.62	9145.955	13383.29	8024.402	14504.84
2013.481	11264.62	9103.778	13425.46	7959.897	14569.34
2013.500	11264.62	9062.409	13466.83	7896.628	14632.61
2013.519	11264.62	9021.802	13507.44	7834.526	14694.72
2013.538	11264.62	8981.918	13547.32	7773.529	14755.71

2013.558	11264.62	8942.719	13586.52	7713.579	14815.66
2013.577	11264.62	8904.171	13625.07	7654.624	14874.62
2013.596	11264.62	8866.242	13663.00	7596.617	14932.62
2013.615	11264.62	8828.904	13700.34	7539.513	14989.73
2013.635	11264.62	8792.129	13737.11	7483.271	15045.97
2013.654	11264.62	8755.894	13773.35	7427.854	15101.39
2013.673	11264.62	8720.174	13809.07	7373.226	15156.02
2013.692	11264.62	8684.949	13844.29	7319.354	15209.89
2013.712	11264.62	8650.199	13879.04	7266.207	15263.03
2013.731	11264.62	8615.904	13913.34	7213.759	15315.48
2013.750	11264.62	8582.048	13947.19	7161.980	15367.26
2013.769	11264.62	8548.614	13980.63	7110.847	15418.39
2013.788	11264.62	8515.586	14013.65	7060.336	15468.91
2013.808	11264.62	8482.951	14046.29	7010.424	15518.82
2013.827	11264.62	8450.694	14078.55	6961.091	15568.15
2013.846	11264.62	8418.803	14110.44	6912.318	15616.92
2013.865	11264.62	8387.265	14141.98	6864.085	15665.16
2013.885	11264.62	8356.069	14173.17	6816.375	15712.87
2013.904	11264.62	8325.204	14204.04	6769.171	15760.07
2013.923	11264.62	8294.660	14234.58	6722.458	15806.78
2013.942	11264.62	8264.427	14264.81	6676.220	15853.02
2013.962	11264.62	8234.495	14294.75	6630.444	15898.80
2013.981	11264.62	8204.856	14324.38	6585.115	15944.13

Accuracy Modelo ARIMA LAN

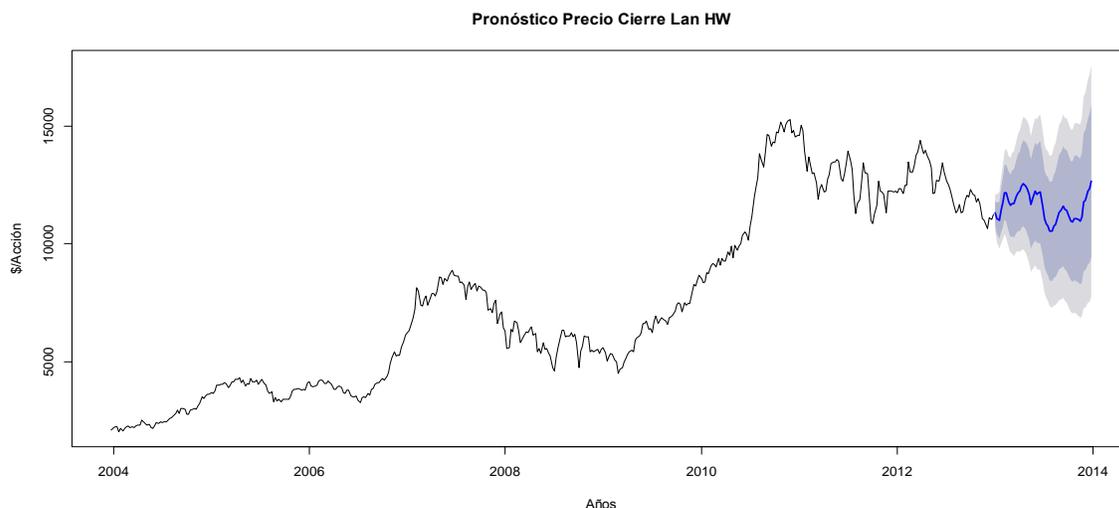
accuracy(forarlan,lan.ts3)

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	18.21806	308.6744	218.5568	0.2557424	3.054745	0.09618351
Test set	-2301.37970	2817.8575	2392.3225	-29.8547137	30.636286	1.05282474

ACF1 Theil's U

Training set	-0.003209762	NA
Test set	0.955089191	9.597837

6.2.1 HOLT-WINTERS LAN



Accuracy Holt-Winters LAN

```
> accuracy(forlanhw,lan.ts3)
      ME  RMSE  MAE   MPE  MAPE  MASE  ACF1 Theil's U
Training set -11.30987 398.3817 282.6081 -0.2183789 3.606372 0.1243715 0.2421789
              NA
Test set    -2633.74444 3019.6660 2692.2384 -33.0992652 33.599155 1.1848132
              0.9138633 9.956197
```

Modelo HW y Pronóstico LAN

```
> summary(forlanhw)
```

Forecast method: HoltWinters

Model Information:

Holt-Winters exponential smoothing with trend and multiplicative seasonal component.

Call:

```
HoltWinters(x = lan.ts2, seasonal = "mult")
```

Smoothing parameters:

```
alpha: 0.8490363
beta : 0
gamma: 1
```

Coefficients:

```
[,1]
a 1.094244e+04
b 2.660569e+01
s1 1.032077e+00
s2 1.008461e+00
```

s3 9.978256e-01
s4 1.035119e+00
s5 1.061999e+00
s6 1.097664e+00
s7 1.092698e+00
s8 1.056949e+00
s9 1.040397e+00
s10 1.046284e+00
s11 1.043091e+00
s12 1.067595e+00
s13 1.079698e+00
s14 1.080989e+00
s15 1.097700e+00
s16 1.106170e+00
s17 1.093975e+00
s18 1.077709e+00
s19 1.055979e+00
s20 1.018579e+00
s21 1.037291e+00
s22 1.060588e+00
s23 1.048634e+00
s24 1.050702e+00
s25 1.050382e+00
s26 9.947509e-01
s27 9.488598e-01
s28 9.294657e-01
s29 9.185453e-01
s30 8.975790e-01
s31 8.970663e-01
s32 9.119724e-01
s33 9.167812e-01
s34 9.340741e-01
s35 9.540124e-01
s36 9.629337e-01
s37 9.723621e-01
s38 9.583214e-01
s39 9.533739e-01
s40 9.279681e-01
s41 9.127003e-01
s42 9.075008e-01
s43 9.175070e-01
s44 9.156262e-01
s45 9.081742e-01
s46 9.005259e-01
s47 9.149601e-01
s48 9.640049e-01
s49 9.682880e-01

s50 9.967045e-01
s51 1.005410e+00
s52 1.028107e+00

Error measures:

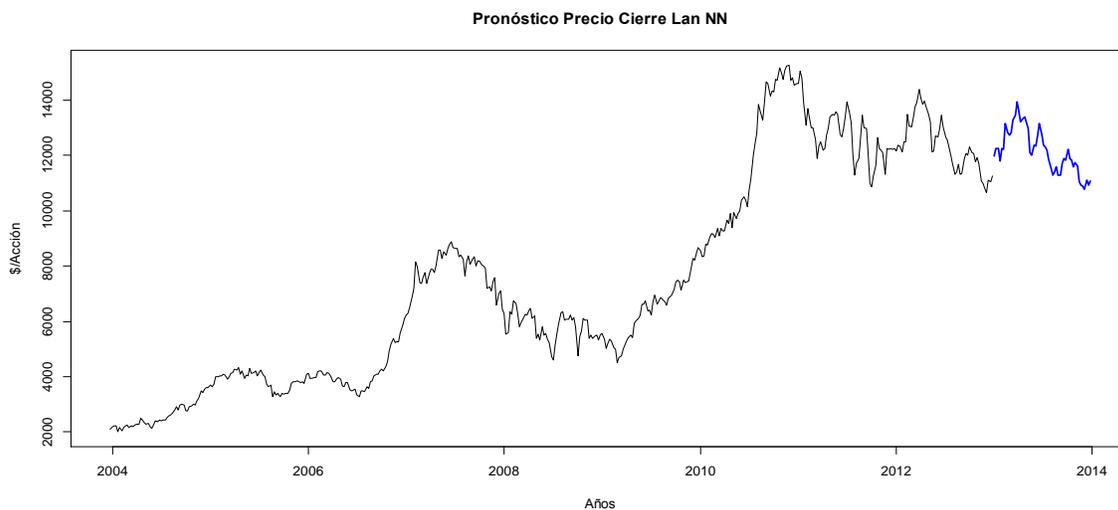
	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	-11.30987	398.3817	282.6081	-0.2183789	3.606372	0.1243715
	ACF1					
Training set	0.2421789					

Forecasts:

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2013.000	11320.90	10809.945	11831.85	10539.463	12102.34
2013.019	11088.68	10424.788	11752.58	10073.342	12104.03
2013.038	10998.29	10210.103	11786.48	9792.862	12203.72
2013.058	11436.88	10514.283	12359.48	10025.888	12847.88
2013.077	11762.14	10722.747	12801.53	10172.525	13351.76
2013.096	12186.35	11029.913	13342.78	10417.734	13954.96
2013.115	12160.29	10929.790	13390.78	10278.404	14042.17
2013.135	11790.56	10521.880	13059.25	9850.279	13730.85
2013.154	11633.60	10310.722	12956.48	9610.433	13656.77
2013.173	11727.27	10328.256	13126.28	9587.663	13866.87
2013.192	11719.23	10258.426	13180.04	9485.122	13953.34
2013.212	12022.94	10467.267	13578.62	9643.742	14402.14
2013.231	12187.97	10556.456	13819.49	9692.783	14683.16
2013.250	12231.31	10541.265	13921.35	9646.611	14816.00
2013.269	12449.59	10680.080	14219.10	9743.360	15155.82
2013.288	12575.08	10740.214	14409.95	9768.895	15381.27
2013.308	12465.56	10599.355	14331.76	9611.448	15319.67
2013.327	12308.89	10419.372	14198.40	9419.124	15198.65
2013.346	12088.79	10186.464	13991.12	9179.434	14998.15
2013.365	11687.74	9800.859	13574.62	8802.006	14573.47
2013.385	11930.05	9960.831	13899.27	8918.389	14941.71
2013.404	12226.21	10167.362	14285.06	9077.474	15374.95
2013.423	12116.31	10034.563	14198.06	8932.552	15300.07
2013.442	12168.15	10037.731	14298.57	8909.955	15426.35
2013.462	12192.40	10018.882	14365.91	8868.292	15516.50
2013.481	11573.12	9467.715	13678.52	8353.181	14793.06
2013.500	11064.46	9008.264	13120.65	7919.780	14209.14
2013.519	10863.04	8801.964	12924.11	7710.899	14015.17
2013.538	10759.84	8676.893	12842.79	7574.246	13945.44
2013.558	10538.12	8456.211	12620.04	7354.113	13722.14
2013.577	10555.97	8430.485	12681.46	7305.320	13806.62
2013.596	10755.64	8552.270	12959.01	7385.877	14125.40
2013.615	10836.74	8579.845	13093.64	7385.114	14288.38
2013.635	11066.01	8726.564	13405.45	7488.138	14643.87
2013.654	11327.60	8899.804	13755.39	7614.607	15040.59

2013.673	11459.15	8970.820	13947.47	7653.580	15264.71
2013.692	11597.22	9047.633	14146.80	7697.965	15496.47
2013.712	11455.25	8904.901	14005.60	7554.826	15355.68
2013.731	11421.48	8847.326	13995.63	7484.653	15358.30
2013.750	11141.80	8598.217	13685.39	7251.724	15031.88
2013.769	10982.77	8443.230	13522.31	7098.879	14866.66
2013.788	10944.35	8382.119	13506.58	7025.757	14862.94
2013.808	11089.43	8463.186	13715.68	7072.934	15105.93
2013.827	11091.06	8434.481	13747.64	7028.171	15153.95
2013.846	11024.96	8354.304	13695.61	6940.545	15109.37
2013.865	10956.07	8272.379	13639.76	6851.720	15060.42
2013.885	11156.02	8395.450	13916.60	6934.091	15377.96
2013.904	11779.67	8840.311	14719.03	7284.308	16275.03
2013.923	11857.77	8873.757	14841.78	7294.117	16421.42
2013.942	12232.28	9130.910	15333.65	7489.144	16975.41
2013.962	12365.87	9207.678	15524.06	7535.834	17195.90
2013.981	12672.38	9454.655	15890.11	7751.293	17593.47

6.2.2 MODELO DE REDES NEURONALES LAN



Pronóstico Modelo NN LAN

> fornlan

Point Forecast

2013	11981.09
2013.01923076923	12256.89
2013.03846153846	12263.76
2013.05769230769	11811.61
2013.07692307692	12244.84
2013.09615384615	12222.37
2013.11538461538	13151.00
2013.13461538462	12813.22
2013.15384615385	12732.61
2013.17307692308	12832.56
2013.19230769231	13284.35
2013.21153846154	13471.83
2013.23076923077	13937.52
2013.25	13618.23
2013.26923076923	13223.54
2013.28846153846	13303.50
2013.30769230769	13394.88
2013.32692307692	13178.28
2013.34615384615	12977.47
2013.36538461538	12089.10
2013.38461538462	12011.30
2013.40384615385	12366.54
2013.42307692308	12357.23
2013.44230769231	12693.65
2013.46153846154	13158.74
2013.48076923077	12763.20
2013.5	12376.87
2013.51923076923	12301.70
2013.53846153846	12180.66
2013.55769230769	11875.28
2013.57692307692	11525.20
2013.59615384615	11276.58
2013.61538461538	11405.93
2013.63461538462	11584.89
2013.65384615385	11278.27
2013.67307692308	11281.19
2013.69230769231	11717.87
2013.71153846154	11898.37
2013.73076923077	11840.40
2013.75	12222.04
2013.76923076923	11900.52
2013.78846153846	11841.00
2013.80769230769	11604.08

```

2013.82692307692    11734.21
2013.84615384615    11631.50
2013.86538461538    11062.18
2013.88461538462    10930.04
2013.90384615385    10893.43
2013.92307692308    10788.45
2013.94230769231    11118.62
2013.96153846154    10926.85
2013.98076923077    11070.50
    
```

Accuracy Modelo NN LAN

```
> accuracy(fornnlan,lan.ts3)
```

```

      ME  RMSE  MAE  MPE  MAPE  MASE
Training set  0.6848712 351.6902 273.0994 -1.322311 3.868808 0.1201869
Test set     -3198.4113226 3477.0642 3198.4113 -39.264163 39.264163 1.4075721
    
```

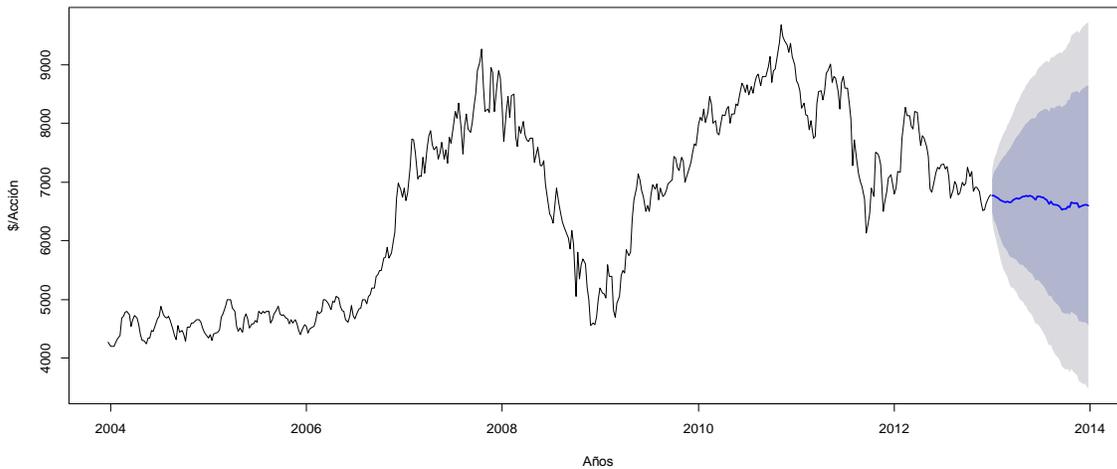
ACF1 Theil's U

```

Training set 0.2851097  NA
Test set    0.9138307 11.26102
    
```

6.3 MODELO ARIMA COPEC

Pronóstico Precio Cierre Copec ARIMA



```

> summary(arcopec)
Series: copec.ts2
ARIMA(0,1,0)(0,0,2)[52]
    
```

```

Coefficients:
sma1  sma2
-0.0305 0.0921
    
```

s.e. **0.0455 0.0538**

**sigma^2 estimated as 48737: log likelihood=-3190.37
AIC=6386.74 AICc=6386.79 BIC=6399.18**

Training set error measures:

ME RMSE MAE MPE MAPE MASE
Training set 4.612463 220.5296 160.1959 0.02878542 2.409977 0.1207392
ACF1
Training set -0.005637729

Pronósticos ARIMA COPEC

> forarcopec

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2013.000	6770.919	6487.997	7053.841	6338.228	7203.610
2013.019	6764.606	6364.494	7164.717	6152.688	7376.524
2013.038	6744.452	6254.417	7234.487	5995.009	7493.896
2013.058	6720.377	6154.533	7286.220	5854.994	7585.759
2013.077	6704.822	6072.190	7337.454	5737.294	7672.349
2013.096	6681.821	5988.807	7374.835	5621.948	7741.694
2013.115	6672.946	5924.405	7421.486	5528.152	7817.740
2013.135	6659.766	5859.543	7459.990	5435.930	7883.602
2013.154	6673.728	5824.963	7522.493	5375.654	7971.802
2013.173	6650.075	5755.398	7544.752	5281.785	8018.365
2013.192	6651.425	5713.080	7589.771	5216.351	8086.500
2013.212	6691.474	5711.405	7671.544	5192.587	8190.361
2013.231	6710.669	5690.580	7730.758	5150.578	8270.760
2013.250	6722.470	5663.874	7781.066	5103.487	8341.453
2013.269	6713.333	5617.582	7809.084	5037.526	8389.139
2013.288	6721.048	5589.361	7852.735	4990.282	8451.813
2013.308	6751.870	5585.354	7918.386	4967.838	8535.903
2013.327	6753.482	5553.147	7953.817	4917.728	8589.236
2013.346	6766.713	5533.486	7999.940	4880.655	8652.771
2013.365	6754.273	5489.009	8019.538	4819.219	8689.328
2013.385	6763.131	5466.621	8059.642	4780.290	8745.973
2013.404	6758.564	5431.543	8085.584	4729.061	8788.066
2013.423	6733.521	5376.676	8090.366	4658.406	8808.636
2013.442	6705.191	5319.163	8091.218	4585.444	8824.937
2013.462	6750.316	5335.708	8164.924	4586.859	8913.773
2013.481	6756.150	5313.527	8198.773	4549.848	8962.452
2013.500	6739.101	5268.997	8209.205	4490.770	8987.431
2013.519	6738.738	5241.657	8235.819	4449.151	9028.326
2013.538	6714.605	5191.025	8238.184	4384.490	9044.719
2013.558	6693.385	5143.759	8243.011	4323.436	9063.333
2013.577	6632.491	5057.250	8207.732	4223.367	9041.615
2013.596	6672.064	5071.618	8272.511	4224.392	9119.737
2013.615	6632.057	5006.795	8257.318	4146.434	9117.679

2013.635	6615.180	4965.477	8264.883	4092.177	9138.183
2013.654	6608.606	4934.819	8282.394	4048.769	9168.443
2013.673	6599.427	4901.897	8296.957	4003.279	9195.575
2013.692	6574.034	4853.088	8294.979	3942.075	9205.993
2013.712	6523.251	4779.205	8267.298	3855.963	9190.540
2013.731	6536.640	4769.794	8303.485	3834.483	9238.797
2013.750	6540.421	4751.067	8329.775	3803.840	9277.001
2013.769	6585.821	4774.238	8397.403	3815.244	9356.397
2013.788	6571.535	4737.993	8405.077	3767.374	9375.696
2013.808	6651.543	4796.301	8506.785	3814.196	9488.890
2013.827	6647.947	4771.257	8524.637	3777.797	9518.097
2013.846	6644.498	4746.602	8542.395	3741.916	9547.081
2013.865	6636.543	4717.674	8555.411	3701.887	9571.198
2013.885	6569.149	4629.536	8508.763	3602.766	9535.532
2013.904	6588.394	4628.255	8548.533	3590.620	9586.168
2013.923	6599.578	4619.126	8580.030	3570.738	9628.418
2013.942	6617.742	4617.184	8618.301	3558.152	9677.332
2013.962	6617.058	4596.593	8637.523	3527.023	9707.092
2013.981	6600.480	4560.303	8640.658	3480.298	9720.662

Accuracy ARIMA COPEC

> accuracy(forarcopec,copec.ts3)

ME RMSE MAE MPE MAPE MASE

Training set 4.612463 220.5296 160.1959 0.02878542 2.409977 0.1207392

Test set 300.928869 482.2444 402.4848 4.05903298 5.673314 0.3033517

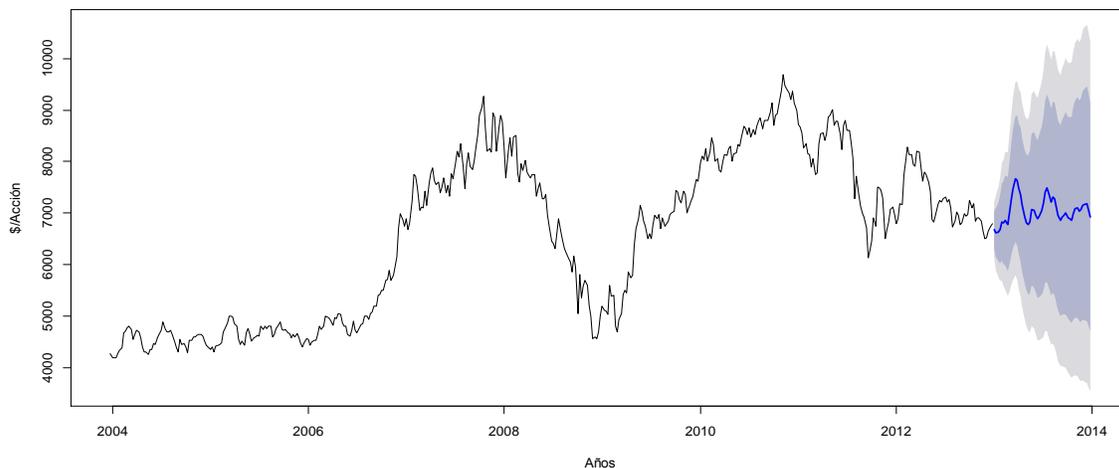
ACF1 Theil's U

Training set -0.005637729 NA

Test set 0.844690228 2.156017

6.3.1 MODELO HW COPEC

Pronóstico Precio Cierre Copec HW



Modelo y Pronóstico HW COPEC

Forecast method: HoltWinters

Model Information:

Holt-Winters exponential smoothing with trend and multiplicative seasonal component.

Call:

HoltWinters(x = copec.ts2, seasonal = "mult")

Smoothing parameters:

alpha: 0.8903418

beta : 0

gamma: 1

Coefficients:

[,1]

a 6980.7348170

b 2.7531337

s1 0.9557266

s2 0.9473825

s3 0.9489424

s4 0.9559032

s5 0.9770698

s6 0.9728572

s7 0.9791627

s8 0.9689557

s9 0.9988658

s10 1.0345573

s11 1.0644405

s12 1.0922667

s13 1.0878999

s14 1.0637088

s15 1.0489278

s16 1.0167089

s17 0.9846903

s18 0.9694019

s19 0.9630533

s20 0.9704047

s21 1.0039233

s22 1.0026608

s23 0.9886168

s24 0.9770178

s25 0.9855530

s26 1.0006166

s27 1.0193942

s28 1.0508274

s29 1.0599195

s30 1.0462834

s31 1.0214103
s32 1.0332770
s33 1.0286862
s34 1.0057035
s35 0.9833465
s36 0.9679440
s37 0.9778066
s38 0.9811181
s39 0.9878754
s40 0.9739958
s41 0.9706865
s42 0.9677133
s43 0.9847722
s44 0.9972096
s45 1.0004077
s46 0.9909510
s47 0.9933131
s48 1.0050929
s49 1.0074407
s50 1.0090344
s51 0.9912124
s52 0.9726770

Error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	1.782065	277.7971	206.0983	-0.02005387	2.991751	0.1553357	0.1660776

Forecasts:

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2013.000	6674.305	6317.873	7030.737	6129.190	7219.420
2013.019	6618.643	6143.247	7094.039	5891.588	7345.698
2013.038	6632.153	6059.992	7204.314	5757.109	7507.197
2013.058	6683.434	6025.780	7341.088	5677.639	7689.229
2013.077	6834.115	6091.549	7576.681	5698.458	7969.772
2013.096	6807.328	6002.596	7612.061	5576.596	8038.061
2013.115	6854.145	5984.443	7723.848	5524.050	8184.241
2013.135	6785.364	5867.786	7702.943	5382.049	8188.679
2013.154	6997.567	6000.678	7994.457	5472.956	8522.179
2013.173	7250.453	6171.161	8329.745	5599.818	8901.088
2013.192	7462.813	6308.558	8617.067	5697.533	9228.092
2013.212	7660.910	6435.274	8886.546	5786.461	9535.359
2013.231	7633.277	6371.883	8894.672	5704.141	9562.413
2013.250	7466.469	6192.496	8740.442	5518.095	9414.842
2013.269	7365.605	6069.591	8661.618	5383.523	9347.686
2013.288	7142.161	5845.877	8438.445	5159.666	9124.657
2013.308	6919.949	5624.370	8215.527	4938.533	8901.365
2013.327	6815.177	5500.519	8129.835	4804.581	8825.773

2013.346	6773.197	5429.019	8117.375	4717.454	8828.940
2013.365	6827.571	5436.597	8218.545	4700.260	8954.882
2013.385	7066.165	5593.197	8539.134	4813.455	9318.876
2013.404	7060.039	5555.062	8565.016	4758.375	9361.703
2013.423	6963.873	5446.180	8481.566	4642.762	9284.985
2013.442	6884.859	5351.567	8418.150	4539.892	9229.826
2013.462	6947.718	5368.958	8526.479	4533.212	9362.224
2013.481	7056.665	5422.909	8690.420	4558.051	9555.278
2013.500	7191.897	5497.793	8886.000	4600.989	9782.804
2013.519	7416.553	5642.076	9191.030	4702.725	10130.381
2013.538	7483.642	5666.022	9301.262	4703.832	10263.452
2013.558	7390.244	5567.974	9212.513	4603.323	10177.164
2013.577	7217.369	5409.994	9024.744	4453.228	9981.511
2013.596	7304.064	5448.521	9159.607	4466.256	10141.873
2013.615	7274.445	5400.024	9148.867	4407.765	10141.125
2013.635	7114.690	5254.559	8974.821	4269.865	9959.515
2013.654	6959.236	5112.664	8805.808	4135.148	9783.324
2013.673	6852.896	5007.531	8698.261	4030.654	9675.138
2013.692	6925.414	5034.570	8816.257	4033.617	9817.210
2013.712	6951.569	5028.010	8875.128	4009.740	9893.398
2013.731	7002.166	5039.626	8964.707	4000.720	10003.613
2013.750	6906.468	4945.463	8867.473	3907.370	9905.566
2013.769	6885.675	4905.690	8865.660	3857.549	9913.800
2013.788	6867.248	4867.940	8866.556	3809.571	9924.925
2013.808	6991.015	4932.091	9049.940	3842.161	10139.869
2013.827	7082.056	4973.273	9190.839	3856.950	10307.162
2013.846	7107.522	4968.346	9246.698	3835.935	10379.110
2013.865	7043.065	4900.362	9185.767	3766.084	10320.045
2013.885	7062.587	4891.488	9233.686	3742.178	10382.997
2013.904	7149.110	4929.603	9368.618	3754.667	10543.554
2013.923	7168.583	4921.399	9415.768	3731.811	10605.356
2013.942	7182.702	4909.718	9455.686	3706.474	10658.931
2013.962	7058.567	4803.086	9314.048	3609.107	10508.027
2013.981	6929.251	4718.095	9140.407	3547.580	10310.923

Accuracy HW COPEC

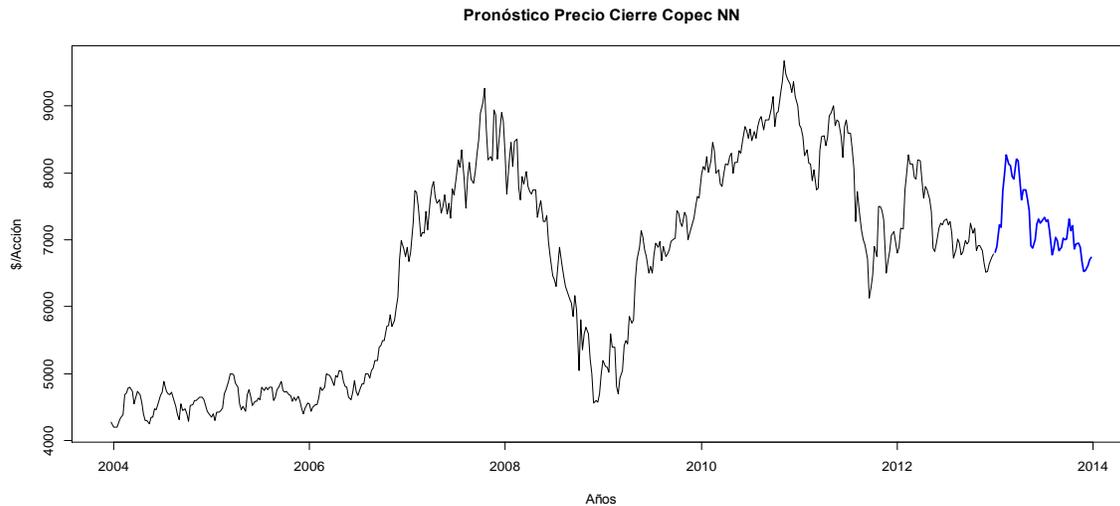
> accuracy(forcopechw,copec.ts3)

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	1.782065	277.7971	206.0983	-0.02005387	2.991751	0.1553357
Test set	-79.928082	482.6970	405.0253	-1.44685941	5.908455	0.3052664

ACF1 Theil's U

Training set	0.1660776	NA
Test set	0.8583496	2.276614

6.3.2 MMODELO NN COPEC



PRONOSTICO NN COPEC

> forncopec

Point Forecast

2013	6811.156
2013.01923076923	6896.838
2013.03846153846	7227.862
2013.05769230769	7185.941
2013.07692307692	7737.190
2013.09615384615	7981.936
2013.11538461538	8276.415
2013.13461538462	8134.989
2013.15384615385	8108.681
2013.17307692308	7949.896
2013.19230769231	7913.453
2013.21153846154	8202.717
2013.23076923077	8185.061
2013.25	7891.364
2013.26923076923	7601.878
2013.28846153846	7753.868
2013.30769230769	7750.171
2013.32692307692	7613.162
2013.34615384615	7441.411
2013.36538461538	6917.465
2013.38461538462	6879.689
2013.40384615385	6998.475

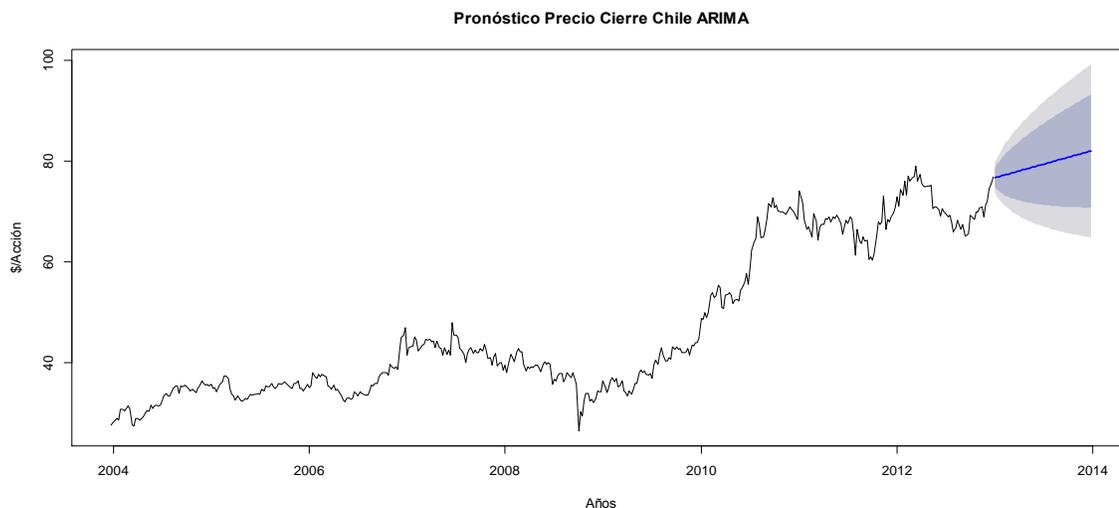
2013.42307692308	7235.472
2013.44230769231	7309.287
2013.46153846154	7252.237
2013.48076923077	7300.069
2013.5	7337.391
2013.51923076923	7271.129
2013.53846153846	7301.698
2013.55769230769	7123.851
2013.57692307692	6773.701
2013.59615384615	6880.837
2013.61538461538	7033.241
2013.63461538462	6986.154
2013.65384615385	6833.210
2013.67307692308	6889.179
2013.69230769231	7026.981
2013.71153846154	6997.187
2013.73076923077	7013.468
2013.75	7308.426
2013.76923076923	7142.034
2013.78846153846	7215.565
2013.80769230769	6869.841
2013.82692307692	6940.950
2013.84615384615	6951.819
2013.86538461538	6883.970
2013.88461538462	6681.888
2013.90384615385	6528.641
2013.92307692308	6543.551
2013.94230769231	6610.493
2013.96153846154	6701.371
2013.98076923077	6734.682

Accuracy NN COPEC

> accuracy(fornncopec,copec.ts3)

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1	Theil's U
Training set	1.777729e-03	221.5908	164.0991	-0.1078455	2.409679	0.123681	-	-
			0.006123982	NA				
Test set	-2.806194e+02	662.5640	543.9824	-4.2992586	7.901039	0.409998		
			0.885982654	3.094777				

6.4 MODELO ARIMA PARA CHILE



Modelo ARIMA y Pronósticos

```
> summary(forarchile)
```

Forecast method: ARIMA(0,1,1) with drift

Model Information:

Series: chile.ts2

ARIMA(0,1,1) with drift

Coefficients:

ma1 drift

-0.1850 0.1043

s.e. 0.0459 0.0558

sigma² estimated as 2.196: log likelihood=-845.81

AIC=1697.62 AICc=1697.67 BIC=1710.07

Error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE
--	----	------	-----	-----	------	------

Training set	0.0003064195	1.478629	0.9933228	-0.09322959	2.144783	0.1349236
--------------	--------------	----------	-----------	-------------	----------	-----------

ACF1

Training set -0.0009058517

Forecasts:

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2013.000	76.70279	74.80380	78.60178	73.79854	79.60705

2013.019	76.80707	74.35734	79.25681	73.06053	80.55362
2013.038	76.91135	74.01373	79.80898	72.47981	81.34289
2013.058	77.01563	73.73063	80.30064	71.99165	82.03962
2013.077	77.11991	73.48862	80.75121	71.56632	82.67351
2013.096	77.22420	73.27687	81.17152	71.18728	83.26111
2013.115	77.32848	73.08862	81.56833	70.84417	83.81278
2013.135	77.43276	72.91928	81.94623	70.52999	84.33552
2013.154	77.53704	72.76561	82.30846	70.23977	84.83430
2013.173	77.64132	72.62519	82.65744	69.96981	85.31282
2013.192	77.74560	72.49616	82.99503	69.71728	85.77391
2013.212	77.84988	72.37707	83.32268	69.47994	86.21981
2013.231	77.95416	72.26675	83.64157	69.25602	86.65230
2013.250	78.05844	72.16423	83.95265	69.04403	87.07285
2013.269	78.16272	72.06873	84.25671	68.84277	87.48267
2013.288	78.26700	71.97957	84.55443	68.65121	87.88279
2013.308	78.37128	71.89619	84.84637	68.46848	88.27407
2013.327	78.47556	71.81810	85.13302	68.29385	88.65727
2013.346	78.57984	71.74487	85.41481	68.12665	89.03303
2013.365	78.68412	71.67613	85.69211	67.96633	89.40191
2013.385	78.78840	71.61157	85.96524	67.81238	89.76442
2013.404	78.89268	71.55088	86.23448	67.66437	90.12099
2013.423	78.99696	71.49383	86.50010	67.52191	90.47202
2013.442	79.10124	71.44017	86.76232	67.38464	90.81784
2013.462	79.20552	71.38970	87.02135	67.25225	91.15879
2013.481	79.30980	71.34224	87.27737	67.12446	91.49515
2013.500	79.41408	71.29761	87.53056	67.00101	91.82716
2013.519	79.51836	71.25566	87.78106	66.88165	92.15507
2013.538	79.62264	71.21626	88.02903	66.76619	92.47910
2013.558	79.72693	71.17928	88.27457	66.65443	92.79942
2013.577	79.83121	71.14459	88.51782	66.54617	93.11624
2013.596	79.93549	71.11209	88.75888	66.44126	93.42971
2013.615	80.03977	71.08167	88.99786	66.33955	93.73999
2013.635	80.14405	71.05326	89.23484	66.24088	94.04721
2013.654	80.24833	71.02675	89.46990	66.14514	94.35151
2013.673	80.35261	71.00207	89.70314	66.05220	94.65302
2013.692	80.45689	70.97915	89.93463	65.96194	94.95184
2013.712	80.56117	70.95791	90.16443	65.87425	95.24809
2013.731	80.66545	70.93829	90.39261	65.78904	95.54186
2013.750	80.76973	70.92023	90.61923	65.70622	95.83324
2013.769	80.87401	70.90367	90.84435	65.62569	96.12233
2013.788	80.97829	70.88855	91.06803	65.54737	96.40921
2013.808	81.08257	70.87484	91.29030	65.47119	96.69395
2013.827	81.18685	70.86247	91.51123	65.39707	96.97663
2013.846	81.29113	70.85141	91.73086	65.32495	97.25731
2013.865	81.39541	70.84160	91.94922	65.25475	97.53607
2013.885	81.49969	70.83302	92.16637	65.18642	97.81296
2013.904	81.60397	70.82562	92.38233	65.11990	98.08805

```

2013.923 81.70825 70.81936 92.59715 65.05513 98.36138
2013.942 81.81253 70.81421 92.81085 64.99205 98.63301
2013.962 81.91681 70.81014 93.02348 64.93063 98.90300
2013.981 82.02109 70.80712 93.23507 64.87081 99.17138
    
```

Accuracy ARIMA CHILE

> accuracy(forarchile,chile.ts3)

```

      ME  RMSE  MAE  MPE  MAPE  MASE
Training set 0.0003064195 1.478629 0.9933228 -0.09322959 2.144783 0.1349236
Test set   -4.3740590051 5.384658 4.7725009 -5.96430317 6.470073 0.6482517
    
```

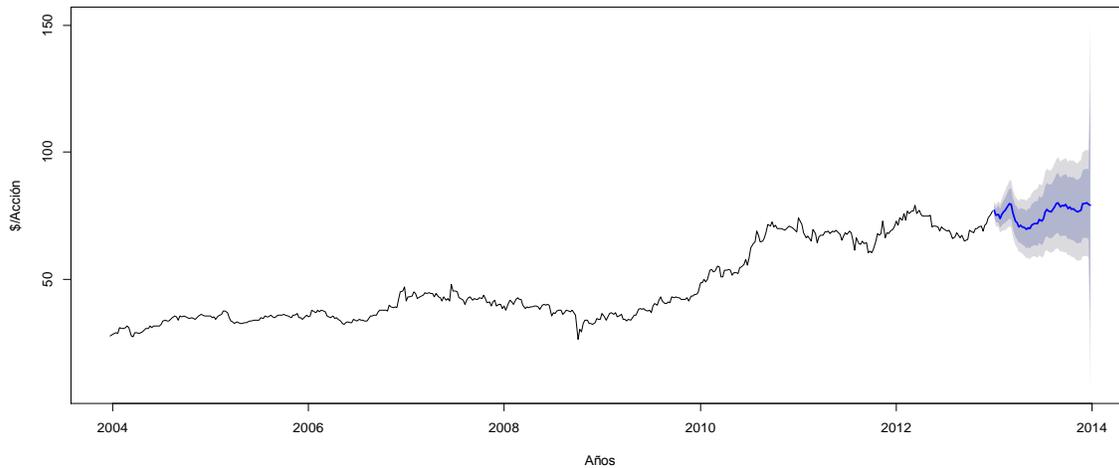
ACF1 Theil's U

```

Training set -0.0009058517  NA
Test set    0.8582349719  3.77931
    
```

MODELO HW CHILE

Pronóstico Precio Cierre Chile HW



6.4.1 MODELO HW Y PRONÓSTICO

> summary(forchilehw)

Forecast method: HoltWinters

Model Information:

Holt-Winters exponential smoothing with trend and multiplicative seasonal component.

Call:

HoltWinters(x = chile.ts2, seasonal = "mult")

Smoothing parameters:

alpha: 0.848151

beta : 0

gamma: 0.5035062

Coefficients:

[,1]

a 74.68011962
b 0.04606453
s1 1.03323726
s2 1.00563846
s3 1.01169958
s4 0.98923966
s5 1.00705732
s6 1.01982781
s7 1.02924282
s8 1.05027427
s9 1.06413672
s10 1.05927487
s11 1.01236685
s12 0.96843066
s13 0.95842262
s14 0.93943696
s15 0.94501027
s16 0.93809659
s17 0.93192742
s18 0.92183001
s19 0.93001761
s20 0.92521666
s21 0.94238523
s22 0.95145448
s23 0.95116837
s24 0.95089989
s25 0.97017859
s26 0.95947523
s27 0.97555357
s28 1.00802467
s29 1.01920847
s30 1.01009876
s31 1.00700026
s32 1.01755100
s33 1.03041057
s34 1.04457166
s35 1.04973785
s36 1.02717416
s37 1.03603271
s38 1.03252102
s39 1.03760973
s40 1.01774610
s41 1.02453076
s42 1.01376229
s43 1.01521769
s44 1.00609805

s45 0.99624165
s46 1.00257667
s47 1.00529565
s48 1.03597758
s49 1.03696311
s50 1.03928574
s51 1.03157559
s52 1.02733253

Error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	0.05914846	1.707113	1.169732	0.03552747	2.413087	0.1588854
	ACF1					
Training set	0.05002215					

Forecasts:

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2013.000	77.20988	75.18585	79.23390	74.114394	80.30536
2013.019	75.19385	72.48052	77.90718	71.044165	79.34353
2013.038	75.69366	72.39358	78.99373	70.646623	80.74069
2013.058	74.05881	70.33215	77.78548	68.359368	79.75825
2013.077	75.43911	71.21816	79.66006	68.983727	81.89449
2013.096	76.44273	71.78422	81.10124	69.318152	83.56731
2013.115	77.19586	72.14221	82.24951	69.466963	84.92475
2013.135	78.82165	73.34313	84.30017	70.442978	87.20032
2013.154	79.91103	74.05939	85.76266	70.961724	88.86033
2013.173	79.59472	73.48060	85.70885	70.243972	88.94548
2013.192	76.11665	69.98082	82.25249	66.732704	85.50060
2013.212	72.85784	66.69717	79.01851	63.435908	82.27977
2013.231	72.14906	65.77458	78.52354	62.400130	81.89798
2013.250	70.76311	64.24293	77.28329	60.791356	80.73486
2013.269	71.22645	64.41043	78.04247	60.802250	81.65065
2013.288	70.74857	63.73163	77.76551	60.017086	81.48006
2013.308	70.32624	63.11183	77.54065	59.292754	81.35973
2013.327	69.60672	62.23196	76.98148	58.327995	80.88545
2013.346	70.26780	62.60013	77.93547	58.541116	81.99449
2013.365	69.94768	62.09647	77.79890	57.940289	81.95508
2013.385	71.28906	63.08094	79.49719	58.735820	83.84231
2013.404	72.01896	63.52714	80.51077	59.031846	85.00607
2013.423	72.04112	63.35117	80.73106	58.750992	85.33124
2013.442	72.06458	63.18089	80.94828	58.478143	85.65102
2013.462	73.57032	64.31975	82.82090	59.422789	87.71786
2013.481	72.80287	63.46708	82.13865	58.525019	87.08072
2013.500	74.06779	64.39683	83.73876	59.277327	88.85826
2013.519	76.57956	66.41784	86.74128	61.038551	92.12057
2013.538	77.47614	67.03597	87.91632	61.509273	93.44301
2013.558	76.83019	66.31752	87.34286	60.752445	92.90793

2013.577	76.64090	65.99710	87.28469	60.362613	92.91918
2013.596	77.49077	66.57700	88.40453	60.799598	94.18193
2013.615	78.51754	67.31171	89.72337	61.379706	95.65538
2013.635	79.64474	68.13496	91.15452	62.042052	97.24742
2013.654	80.08700	68.37250	91.80149	62.171226	98.00277
2013.673	78.41288	66.79960	90.02615	60.651903	96.17385
2013.692	79.13685	67.27766	90.99604	60.999782	97.27391
2013.712	78.91617	66.95205	90.88029	60.618629	97.21371
2013.731	79.35290	67.18757	91.51823	60.747631	97.95817
2013.750	77.88068	65.80363	89.95773	59.410433	96.35093
2013.769	78.44706	66.14890	90.74521	59.638648	97.25546
2013.788	77.66923	65.35895	89.97950	58.842291	96.49616
2013.808	77.82750	65.36060	90.29439	58.761023	96.89397
2013.827	77.17472	64.68062	89.66882	58.066645	96.28280
2013.846	76.46456	63.95381	88.97531	57.331023	95.59809
2013.865	76.99697	64.27084	89.72311	57.534025	96.45992
2013.885	77.25210	64.35722	90.14698	57.531084	96.97311
2013.904	79.65758	66.24156	93.07359	59.139556	100.17560
2013.923	79.78112	66.22465	93.33759	59.048287	100.51396
2013.942	80.00769	66.29469	93.72069	59.035468	100.97992
2013.962	79.46166	65.72400	93.19932	58.451715	100.47160
2013.981	79.18214	32.02132	126.34296	7.055895	151.30839

Accuracy HW CHILE

accuracy(forchilehw,chile.ts3)

ME RMSE MAE MPE MAPE MASE

Training set 0.05914846 1.707113 1.169732 0.03552747 2.413087 0.1588854

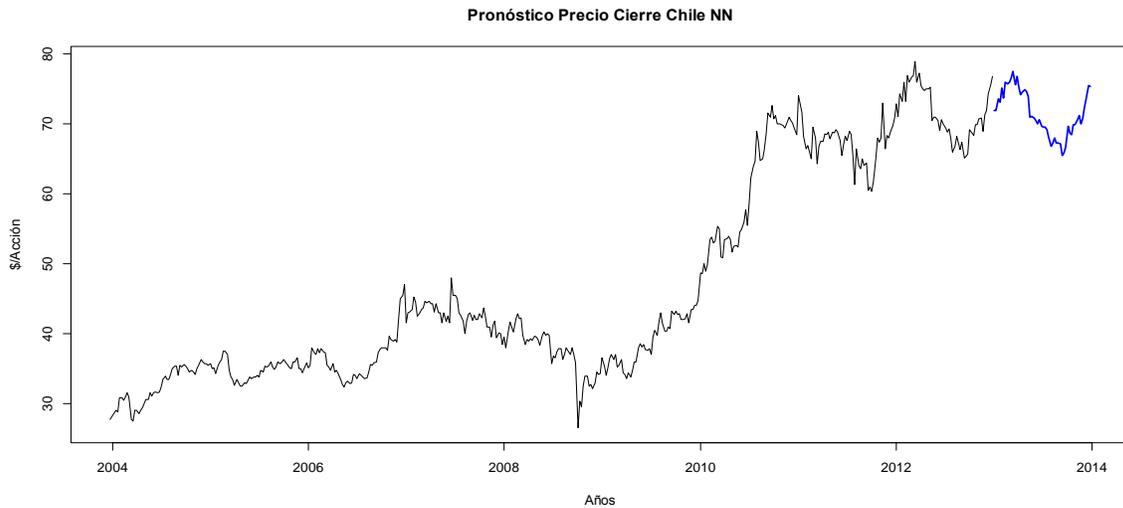
Test set -0.94124545 3.155889 2.607087 -1.30362696 3.514078 0.3541222

ACF1 Theil's U

Training set 0.05002215 NA

Test set 0.80347094 2.207954

6.4.2 MODELO NN CHILE



Modelo NN y Pronóstico
> summary(fornnchile)

Forecast method: NNAR(8,1)

Model Information:

Average of 20 networks, each of which is
a 9-5-1 network with 56 weights
options were - linear output units

Error measures:

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	0.007714575	1.497424	1.017893	-0.08617224	2.131338	0.138261
			0.01223514			

Forecasts:

Point Forecast

2013	71.99366
2013.01923076923	71.92359
2013.03846153846	73.60859
2013.05769230769	73.16331
2013.07692307692	75.13950
2013.09615384615	73.74298
2013.11538461538	75.93997
2013.13461538462	75.81254
2013.15384615385	75.96518
2013.17307692308	76.55152
2013.19230769231	77.51888
2013.21153846154	75.58754
2013.23076923077	76.85327

2013.25	75.29082
2013.26923076923	74.19515
2013.28846153846	74.58764
2013.30769230769	74.88653
2013.32692307692	74.67503
2013.34615384615	74.00624
2013.36538461538	70.94577
2013.38461538462	71.16114
2013.40384615385	70.93023
2013.42307692308	70.47490
2013.44230769231	70.00943
2013.46153846154	70.62503
2013.48076923077	69.71271
2013.5	69.60592
2013.51923076923	69.55148
2013.53846153846	69.22581
2013.55769230769	68.09168
2013.57692307692	66.78402
2013.59615384615	67.25168
2013.61538461538	67.95708
2013.63461538462	67.32970
2013.65384615385	67.32838
2013.67307692308	67.15882
2013.69230769231	65.50679
2013.71153846154	65.83456
2013.73076923077	66.66658
2013.75	69.64855
2013.76923076923	68.76051
2013.78846153846	68.52224
2013.80769230769	69.91154
2013.82692307692	69.89666
2013.84615384615	70.66699
2013.86538461538	71.17702
2013.88461538462	70.01048
2013.90384615385	70.78532
2013.92307692308	72.25413
2013.94230769231	74.17291
2013.96153846154	75.47968
2013.98076923077	75.42876

Accuracy NN Chile

> accuracy(fornnchile,chile.ts3)

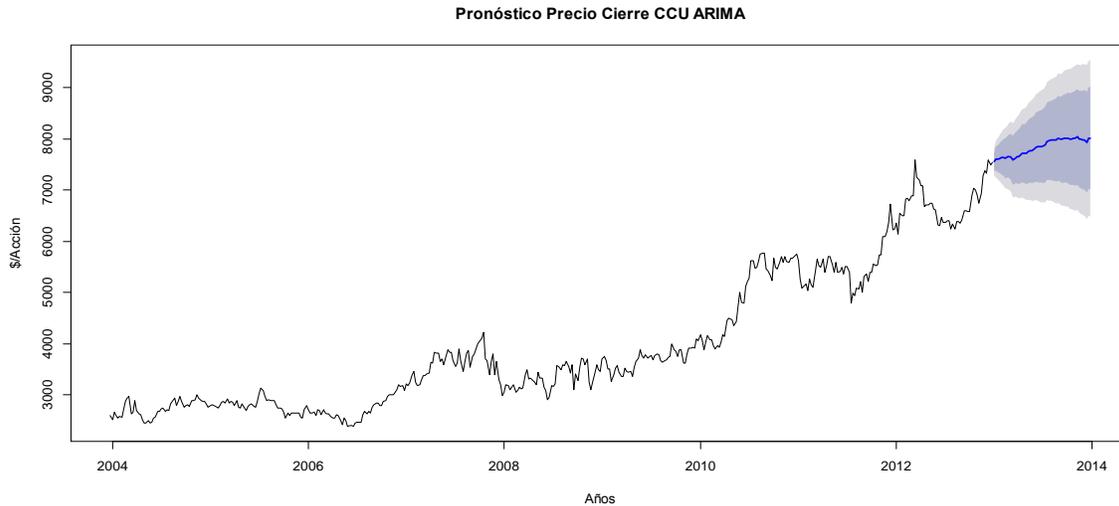
	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	0.007714575	1.497424	1.017893	-0.08617224	2.131338	0.1382610
Test set	3.443491472	4.989475	4.106765	4.51526573	5.425758	0.5578245

ACF1 Theil's U

Training set	-0.01223514	NA
--------------	-------------	----

Test set 0.85757784 3.367088

6.5 MODELO ARIMA PARA CCU



Modelo y Pronóstico ARIMA CCU > summary(forarccu)

Forecast method: ARIMA(0,1,2)(0,0,2)[52] with drift

Model Information:

Series: ccu.ts2

ARIMA(0,1,2)(0,0,2)[52] with drift

Coefficients:

ma1	ma2	sma1	sma2	drift
-0.1594	-0.0714	-0.0779	-0.0910	10.5397
s.e. 0.0462	0.0464	0.0508	0.0541	4.2776

sigma² estimated as 19458: log likelihood=-2968.84

AIC=5949.67 AICc=5949.85 BIC=5974.56

Error measures:

ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set -0.4209244	139.1941	99.31262	-0.174244	2.537716	0.1492304	-0.0001129488

Forecasts:

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2013.000	7553.497	7374.731	7732.263	7280.098	7826.896
2013.019	7613.109	7379.569	7846.649	7255.941	7970.278
2013.038	7615.813	7344.795	7886.832	7201.326	8030.301
2013.058	7628.966	7325.055	7932.876	7164.175	8093.756
2013.077	7634.685	7301.111	7968.259	7124.527	8144.842

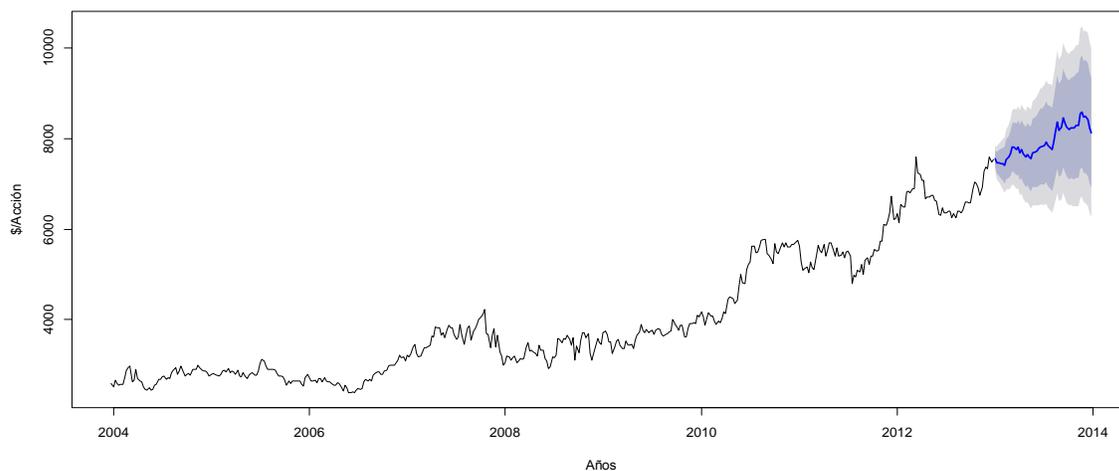
2013.096	7638.547	7277.740	7999.354	7086.740	8190.354
2013.115	7625.565	7239.441	8011.689	7035.039	8216.091
2013.135	7654.143	7244.263	8064.024	7027.285	8281.002
2013.154	7663.898	7231.564	8096.232	7002.700	8325.095
2013.173	7645.849	7192.172	8099.526	6952.010	8339.688
2013.192	7584.118	7110.057	8058.178	6859.105	8309.130
2013.212	7632.696	7139.094	8126.299	6877.797	8387.596
2013.231	7649.446	7137.047	8161.846	6865.798	8433.094
2013.250	7655.805	7125.274	8186.337	6844.428	8467.183
2013.269	7689.221	7141.157	8237.285	6851.030	8527.412
2013.288	7719.859	7154.807	8284.912	6855.686	8584.032
2013.308	7715.013	7133.469	8296.558	6825.617	8604.409
2013.327	7726.168	7128.585	8323.750	6812.244	8640.091
2013.346	7752.419	7139.219	8365.620	6814.610	8690.229
2013.365	7776.161	7147.730	8404.592	6815.059	8737.263
2013.385	7773.306	7130.006	8416.606	6789.463	8757.149
2013.404	7803.033	7145.199	8460.867	6796.963	8809.103
2013.423	7840.720	7168.667	8512.773	6812.903	8868.537
2013.442	7846.798	7160.820	8532.776	6797.685	8895.911
2013.462	7855.596	7155.970	8555.222	6785.610	8925.581
2013.481	7860.324	7147.312	8573.337	6769.866	8950.783
2013.500	7870.669	7144.517	8596.821	6760.115	8981.222
2013.519	7887.299	7148.240	8626.357	6757.007	9017.591
2013.538	7957.581	7205.838	8709.324	6807.890	9107.273
2013.558	7965.220	7201.003	8729.437	6796.451	9133.989
2013.577	7975.061	7198.570	8751.551	6787.521	9162.600
2013.596	7980.355	7191.782	8768.929	6774.336	9186.374
2013.615	7982.111	7181.637	8782.584	6757.892	9206.330
2013.635	7979.027	7166.827	8791.226	6736.874	9221.179
2013.654	8016.331	7192.572	8840.090	6756.501	9276.161
2013.673	7997.178	7162.020	8832.336	6719.914	9274.442
2013.692	7991.272	7144.869	8837.676	6696.810	9285.735
2013.712	8017.476	7159.975	8874.978	6706.040	9328.912
2013.731	8015.824	7147.366	8884.282	6687.632	9344.016
2013.750	8022.751	7143.473	8902.029	6678.012	9367.491
2013.769	7998.214	7108.247	8888.180	6637.128	9359.300
2013.788	8002.302	7101.774	8902.830	6625.064	9379.540
2013.808	8015.344	7104.378	8926.311	6622.141	9408.548
2013.827	8016.550	7095.262	8937.838	6607.562	9425.538
2013.846	8043.563	7112.069	8975.057	6618.966	9468.160
2013.865	8003.959	7062.370	8945.549	6563.922	9443.996
2013.885	7990.943	7039.364	8942.521	6535.629	9446.256
2013.904	7986.339	7024.876	8947.802	6515.908	9456.770
2013.923	7983.328	7012.081	8954.576	6497.933	9468.723
2013.942	7941.662	6960.727	8922.596	6441.452	9441.871
2013.962	8009.879	7019.353	9000.405	6495.000	9524.758
2013.981	8016.556	7016.530	9016.583	6487.148	9545.965

Accuracy ARIMA CCU

```
> accuracy(forarccu,ccu.ts3)
      ME  RMSE  MAE   MPE  MAPE  MASE
Training set -0.4209244 139.1941 99.31262 -0.174244 2.537716 0.1492304
Test set    -733.0540191 989.7004 814.56320 -11.073516 12.099654 1.2239895
      ACF1 Theil's U
Training set -0.0001129488    NA
Test set     0.8697696571 3.820189
```

MODELO HW CCU

Pronóstico Precio Cierre CCU HW



Modelo HW y Pronóstico

```
> summary(forccuhw)
```

Forecast method: HoltWinters

Model Information:

Holt-Winters exponential smoothing with trend and multiplicative seasonal component.

Call:

```
HoltWinters(x = ccu.ts2, seasonal = "mult")
```

Smoothing parameters:

```
alpha: 0.7655201
beta : 0.003294011
gamma: 0.4481723
```

Coefficients:

```
[,1]
a 7609.5708505
```

b 11.8171194
s1 0.9923236
s2 0.9787062
s3 0.9766884
s4 0.9728446
s5 0.9700638
s6 0.9649679
s7 0.9802803
s8 0.9861896
s9 0.9949502
s10 1.0102575
s11 1.0102376
s12 1.0017401
s13 1.0057176
s14 0.9895640
s15 0.9976594
s16 0.9841503
s17 0.9727825
s18 0.9788369
s19 0.9697464
s20 0.9625206
s21 0.9778059
s22 0.9789643
s23 0.9804014
s24 0.9844554
s25 0.9896180
s26 0.9902347
s27 0.9914209
s28 0.9988460
s29 0.9866174
s30 0.9824288
s31 0.9734388
s32 0.9950675
s33 1.0202762
s34 1.0441006
s35 1.0201411
s36 1.0276135
s37 1.0512614
s38 1.0359881
s39 1.0223063
s40 1.0144887
s41 1.0179830
s42 1.0156871
s43 1.0151676
s44 1.0193816
s45 1.0191323
s46 1.0499420

s47 1.0527152
s48 1.0377429
s49 1.0372999
s50 1.0278325
s51 1.0040347
s52 0.9875002

Error measures:

ME RMSE MAE MPE MAPE MASE
Training set 8.726165 161.3689 118.0867 0.09781971 2.894508 0.1774409
ACF1
Training set 0.05797656

Forecasts:

Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2013.000	7562.883	7382.886	7742.879	7287.602
2013.019	7470.665	7232.073	7709.257	7105.770
2013.038	7466.804	7180.280	7753.329	7028.603
2013.058	7448.914	7121.735	7776.094	6948.537
2013.077	7439.086	7075.524	7802.649	6883.066
2013.096	7411.410	7015.521	7807.300	6805.950
2013.115	7540.601	7107.513	7973.689	6878.250
2013.135	7597.711	7132.968	8062.453	6886.948
2013.154	7676.961	7180.832	8173.090	6918.198
2013.173	7807.010	7277.670	8336.349	6997.455
2013.192	7818.794	7264.707	8372.881	6971.390
2013.212	7764.864	7191.319	8338.410	6887.702
2013.231	7807.580	7208.696	8406.465	6891.665
2013.250	7693.870	7081.728	8306.012	6757.680
2013.269	7768.602	7129.686	8407.518	6791.465
2013.288	7675.038	7023.122	8326.955	6678.018
2013.308	7597.880	6932.239	8263.521	6579.870
2013.327	7656.735	6966.515	8346.955	6601.135
2013.346	7597.087	6893.002	8301.171	6520.282
2013.365	7551.853	6833.094	8270.613	6452.605
2013.385	7683.335	6934.115	8432.554	6537.503
2013.404	7704.006	6935.086	8472.927	6528.044
2013.423	7726.901	6938.398	8515.404	6520.990
2013.442	7770.485	6960.657	8580.313	6531.961
2013.462	7822.929	6991.152	8654.707	6550.836
2013.481	7839.506	6989.739	8689.273	6539.899
2013.500	7860.612	6992.623	8728.602	6533.137
2013.519	7931.287	7039.962	8822.611	6568.123
2013.538	7845.845	6948.515	8743.176	6473.496
2013.558	7824.146	6913.938	8734.354	6432.103
2013.577	7764.052	6845.553	8682.551	6359.328
2013.596	7948.319	6993.460	8903.178	6487.987

2013.615	8161.736	7167.164	9156.309	6640.669	9682.803
2013.635	8364.658	7331.677	9397.639	6784.850	9944.467
2013.654	8184.765	7159.902	9209.629	6617.372	9752.159
2013.673	8256.861	7209.324	9304.399	6654.792	9858.931
2013.692	8459.295	7372.910	9545.680	6797.812	10120.778
2013.712	8348.636	7263.034	9434.238	6688.351	10008.922
2013.731	8250.460	7164.214	9336.706	6589.190	9911.730
2013.750	8199.357	7106.530	9292.184	6528.022	9870.691
2013.769	8239.628	7128.366	9350.891	6540.099	9939.158
2013.788	8233.048	7109.673	9356.423	6514.995	9951.101
2013.808	8240.833	7103.527	9378.139	6501.473	9980.193
2013.827	8287.087	7130.714	9443.460	6518.568	10055.606
2013.846	8297.104	7126.734	9467.474	6507.177	10087.030
2013.865	8560.343	7340.791	9779.896	6695.198	10425.488
2013.885	8595.393	7358.745	9832.042	6704.103	10486.684
2013.904	8485.409	7252.360	9718.457	6599.624	10371.193
2013.923	8494.044	7247.691	9740.396	6587.912	10400.176
2013.942	8428.665	7179.825	9677.506	6518.729	10338.602
2013.962	8245.378	7011.434	9479.321	6358.224	10132.531
2013.981	8121.262	6906.807	9335.717	6263.914	9978.611

Accuracy Modelo HW

> accuracy(forccuhw,ccu.ts3)

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	8.726165	161.3689	118.0867	0.09781971	2.894508	0.1774409
Test set	-823.318352	1164.1532	909.2024	-12.50195745	13.590093	1.3661974

ACF1 Theil's U

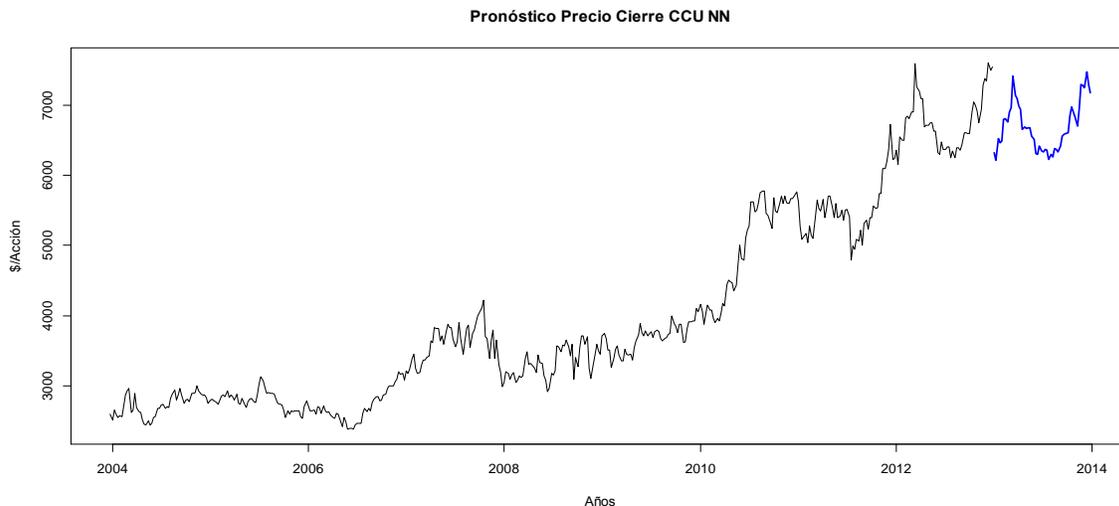
Training set 0.05797656 NA

Test set 0.90496269 4.534114

MODELO NN CCU

> plot(fornnccu,main="Pronóstico Precio Cierre CCU NN",xlab="Años",ylab="\$ / Acción")

>



summary(fornnccu)
Forecast method: NNAR(8,1)

Model Information:

Average of 20 networks, each of which is
a 9-5-1 network with 56 weights
options were - linear output units

Error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	-0.007584613	157.9109	118.1461	-0.6302065	2.953964	0.1775303

ACF1

Training set 0.2154362

Forecasts:

Point Forecast

2013	6320.235
2013.01923076923	6209.319
2013.03846153846	6522.527
2013.05769230769	6463.698
2013.07692307692	6484.732
2013.09615384615	6790.381
2013.11538461538	6807.043
2013.13461538462	6753.103
2013.15384615385	6899.139
2013.17307692308	6963.083
2013.19230769231	7403.439

2013.21153846154	7140.835
2013.23076923077	7088.196
2013.25	6984.802
2013.26923076923	6936.826
2013.28846153846	6645.673
2013.30769230769	6689.176
2013.32692307692	6661.304
2013.34615384615	6671.213
2013.36538461538	6679.958
2013.38461538462	6562.029
2013.40384615385	6513.297
2013.42307692308	6307.414
2013.44230769231	6301.522
2013.46153846154	6417.574
2013.48076923077	6342.811
2013.5	6334.963
2013.51923076923	6362.938
2013.53846153846	6359.638
2013.55769230769	6229.129
2013.57692307692	6294.928
2013.59615384615	6254.467
2013.61538461538	6376.463
2013.63461538462	6363.903
2013.65384615385	6330.393
2013.67307692308	6416.186
2013.69230769231	6561.877
2013.71153846154	6580.122
2013.73076923077	6596.178
2013.75	6603.873
2013.76923076923	6840.521
2013.78846153846	6965.410
2013.80769230769	6905.388
2013.82692307692	6829.982
2013.84615384615	6696.973
2013.86538461538	6943.810
2013.88461538462	7287.361
2013.90384615385	7280.053
2013.92307692308	7242.144
2013.94230769231	7468.744
2013.96153846154	7290.545
2013.98076923077	7167.175

Accuracy Modelo NN

> accuracy(fornccu,ccu.ts3)

	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	-0.007584613	157.9109	118.1461	-0.6302065	2.953964	0.1775303
Test set	420.469047549	797.1876	682.1871	5.3027603	9.496061	1.0250767

ACF1 Theil's U
Training set 0.2154362 NA
Test set 0.8218860 2.797305

BIBLIOGRAFÍA

- Alberto, J., Torres, V., & Delgado, A. (2007). Entrenamiento de una red neuronal multicapa para la tasa de cambio euro - dólar (EUR / USD) Training a multilayer neural network for the Euro-dollar (EUR / USD) exchange rate. *Ingeniería E Investigación*, 27(3), 106–117.
- Arancibia, Franco ; Loehnert, Francisco ; Soto, G. (2008). *Predicción De Signo Semanales De Las Acciones De Falabella, Ripley, Cencosud Y D&S Con Redes Neuronales*. UNIVERSIDAD DE CHILE.
- Arrieta, Jaime ; Torres, Juan ; Velásquez, H. (2009). Predicciones De Modelos Econométricos Y Redes Neuronales: El Caso De La Acción De Suraminv. *Semestre Económico*, 12(25), 95–109.
- Asadi, S., Hadavandi, E., Mehmanpazir, F., & Nakhostin, M. M. (2012). Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction. *Knowledge-Based Systems*, 35, 245–258. doi:10.1016/j.knosys.2012.05.003
- Botero, S. B., Cano, S., Alfonso, J., & De, A. (2008). Análisis de series de tiempo para la predicción de los precios de la energía en la bolsa de colombia. *CUADERNOS DE ECONOMÍA*, 48, 176–208.
- Chang, P.-C., Wang, D., & Zhou, C. (2012). A novel model by evolving partially connected neural network for stock price trend forecasting. *Expert Systems with Applications*, 39(1), 611–620. doi:10.1016/j.eswa.2011.07.051
- De Faria, E. L., Albuquerque, M. P., Gonzalez, J. L., Cavalcante, J. T. P., & Albuquerque, M. P. (2009). Predicting the Brazilian stock market through neural networks and adaptive exponential smoothing methods. *Expert Systems with Applications*, 36(10), 12506–12509. doi:10.1016/j.eswa.2009.04.032
- Duarte, J. V. C. (2001). *Predicción Con Redes Neuronales: Comparación Con Las Metodologías De Box Y Jenkins*. UNIVERSIDAD DE LOS ANDES.
- Evans, C., Pappas, K., & Xhafa, F. (2013). Utilizing artificial neural networks and genetic algorithms to build an algo-trading model for intra-day foreign exchange speculation. *Mathematical and Computer Modelling*, 58(5-6), 1249–1266. doi:10.1016/j.mcm.2013.02.002
- Fiszelew, A., & García-Martínez, R. (2010). *GENERACIÓN AUTOMÁTICA DE REDES NEURONALES CON AJUSTE DE PARÁMETROS BASADO EN ALGORITMOS GENÉTICOS*. Universidad de Buenos Aires.

- Gomes, G. S. D. S., & Ludermir, T. B. (2013). Optimization of the weights and asymmetric activation function family of neural network for time series forecasting. *Expert Systems with Applications*, 40(16), 6438–6446. doi:10.1016/j.eswa.2013.05.053
- Gómez, D. G. (2001). TEÓRICAS Y APLICABILIDAD. *Economía y Sociedad*, (16), 45–60.
- González, F. J. B. (2006). *Determinación De Óptimos De Rolling*, En Modelos Arimax. UNIVERSIDAD DE CHILE.
- González, K. (2005). *Uso de Redes Neuronales Artificiales para Predecir los Retornos Accionarios en el Mercado Bursatil Chileno*. UNIVERSIDAD DE TALCA.
- Grado, T. D. E., & Ingenier, E. N. (2005). Entrenamiento de redes neuronales basado en algoritmos evolutivos.
- Granados, R. M. (2011). Efectos fijos o aleatorios : test de especificación. *Documentos de Trabajo en Economía Aplicada*, 1–5.
- Güemes, G., Redes, D., & Artificiales, N. (n.d.). Aplicaciones De Redes Neuronales En Economía. *V Jornadas Asepuma Aplicaciones*, 1–8.
- Guresen, E., Kayakutlu, G., & Daim, T. U. (2011). Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*, 38(8), 10389–10397. doi:10.1016/j.eswa.2011.02.068
- Ikeda, R. H. (2004). *DIVULGAÇÃO DE TRABALHO MERCADOS EFICIENTES E ARBITRAGEM : UM ESTUDO SOB O*.
- J. D. Velasquez, C. J. F. (2012). Pronostico de series de tiempo con tendencia y ciclo estacional usando el modelo airline y redes neuronales artificiale. *Ingeniería y Ciencia*, 8(15), 171–189.
- Leiva, G. A., & Cuello, K. C. (2011). Análisis de rendimiento académico estudiantil usando data warehouse y redes neuronales. *Ingeniare. Revista chilena de ingeniería*, 19(3), 369–381.
- Madrid, Aracely ; Chaparro, Adrián ; Bustos, Raime ; Rios, A. (2011). Diseño de una herramienta de planificación estratégica aplicando teoría de redes neuronales artificiales. *Revista Internacional Administración & Finanzas*, 4(4), 31–45.
- Marcelo Gutiérrez Márquez. (2004). *Administración de carteras con redes neuronales mediante metodología Rolling*. UNIVERSIDAD DE CHILE.
- MONTAÑO MORENO, J. jose. (2002). *Redes Neuronales Artificiales aplicadas al Análisis de Datos*. UNIVERSITAT DE LES ILLES BALEARS.

- Muñoz Gutiérrez, C. (1982). *Redes neurales*.
- Neuronales, L. R., & Networks, N. (n.d.). Introducción a las redes neuronales aplicadas, 1–31.
- Parisi, Antonino; Parisi, Franco ; Diaz, D. (2006). Modelos De Algoritmos Genéticos Y Redes Neuronales En La Predicción De Índices Bursátiles Asiáticos. *Cuadernos De Economía*, 43(Noviembre), 251–284.
- Parisi, Rebolledo, C. (2006). Modelos de lógica y lógica borrosa en la Predicción del IPSA. *Estudios de Administración*, 13(1), 37–66.
- Park, K., & Shin, H. (2013). Stock price prediction based on a complex interrelation network of economic factors. *Engineering Applications of Artificial Intelligence*, 26(5-6), 1550–1561. doi:10.1016/j.engappai.2013.01.009
- Patiño, V. M. O. (2012). Redes Neuronales Artificiales en las Ciencias Económicas Viviana. *Facultad de Ciencias Económicas de la Universidad Nacional de Colombia*, 1–24.
- Pitarque, A., Francisco, J., & Carlos, J. (1998). Redes neurales vs modelos estadísticos : Simulaciones sobre tareas de predicción y clasificación. *Psicológica*, 19, 387–400.
- Reyes, Daniel; Tapia, V. (2000). *Evaluación De Los Distintos Modelos De Redes Neuronales En La Predicción De Valores Financieros*. Universidad de Talca.
- Robb, A. M., & Coleman, S. (2010). Financing Strategies of New Technology-Based Firms : A Comparison of Women-and Men-Owned Firms. *Journal of Technology Management & Innovation*, 5(1), 21.
- Ruiz, C. A., & Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Universidad Tecnológica Nacional – Facultad Regional Rosario.
- Santana, J. C. (2006). Predicción de series temporales con redes neuronales: una aplicación a la inflación colombiana. *Revista Colombiana de Estadística*, 29(1), 77–92.
- Serrano, Carlos ; Martín del Brío, B. (1993). Predicción De La Quiebra Bancaria Mediante El Empleo De Redes Neuronales Artificiales. *Revista Española De Financiación Y Contabilidad*, 23(74), 153–176.
- Ticknor, J. L. (2013). A Bayesian regularized artificial neural network for stock market forecasting. *Expert Systems with Applications*, 40(14), 5501–5506. doi:10.1016/j.eswa.2013.04.013

- Vel, J. D., & Zambrano, C. (2011). ARNN: Un paquete para la predicción de series de tiempo usando redes neuronales autorregresivas ARNN: A packages for time series forecasting using autoregressive neural networks, 8(2).
- Vidal, T. A., & Depto. (2012). *Introducción a las Redes Neuronales Tomás Arredondo Vidal*. U.Tecnica Feredico Santa María.
- Villada, F., Muñoz, N., & García, E. (2012a). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. *Información tecnológica*, 23(4), 11–20. doi:10.4067/S0718-07642012000400003
- Villada, F., Muñoz, N., & García, E. (2012b). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. *Información tecnológica*, 23(4), 11–20. doi:10.4067/S0718-07642012000400003
- Vol. 13, N°1, Otoño 2006, Parisi, Rebolledo, Cornejo.pdf. (n.d.).