



Universidad de Chile
Facultad de Economía y Negocios
Escuela de Economía y Administración

Predicción de Signo mediante Redes Neuronales en el Mercado de Inmuebles

Seminario para optar al título de
Ingeniero Comercial Mención Economía

Profesor Guía: Antonino Parisi Fernández
Autor: Oliver Witt Fuchs

Santiago de Chile
Noviembre de 2007

*A mi familia,
por su amor y apoyo incondicionales.*

*A Antonino Parisi, Jaime Rivera y Gabriel Valenzuela,
por su apoyo y colaboración constantes.*

*A la Universidad de Chile y su Estudiantado,
por la experiencia única que me han brindado.*

Resumen Ejecutivo

El objetivo de esta tesis es probar la existencia de capacidad de predicción en el mercado inmobiliario mediante la aplicación de un modelo de redes neuronales. Para ello se utilizó una base de datos con los precios promedio del metro cuadrado de casas y departamentos en distintas comunas y sectores de la capital, entre los años 1994 y 2007, con una frecuencia mensual.

La metodología empleada consiste en una red neuronal Ward con rolling, de los rezagos de las diferencias del precio promedio de inmuebles en una comuna sobre los rezagos de las diferencias de la Tasa de Interés Promedio (TIP) y el Índice Mensual de Actividad Económica (IMACEC).

Mediante el test de acierto direccional de Pesaran y Timmermann logramos determinar capacidad de predicción en cuatro zonas de la capital en que además los resultados del modelo superaban la metodología Buy & Hold, resultados que pudimos corroborar al aplicar el modelo a sucesivas submuestras de nuestra serie original.

Se concluye que, pese a todas las limitaciones de información inherentes a la base de datos utilizada, sí existe capacidad predictiva en el mercado inmobiliario, aunque estos resultados no sean homogéneos a través de las comunas de la capital.

Índice

1. Introducción	5
2. Marco Teórico.....	6
i. El Mercado Inmobiliario	8
ii. Redes Neuronales Artificiales.....	9
a) Sistemas Paralelos, Distribuidos y Adaptativos.....	10
b) La Neurona	11
c) Funciones de Activación	13
d) Arquitectura de RNA	15
e) Proceso de Aprendizaje	17
f) Generalización Versus Memorización	18
g) Síntesis sobre Redes Neuronales	19
3. Metodología	20
i. Los Datos	20
ii. RNA Utilizada: Ward.....	24
iii. <i>Rolling</i> Vs. Recursivo.....	25
iv. Validación de los Resultados.....	26
4. Resultados	29
5. Conclusiones	32
i. Conclusiones del Modelo	32
ii. Futuras Áreas de Investigación	34
Bibliografía	36
Anexos	38
i. Evolución Tasa de Interés Promedio (colocaciones 90-365 días) en UF	38
ii. Evolución IMACEC, base 100 = Enero 2003 (serie estacional)	38
iii. Desglose del Mercado de la Construcción	39
iv. Descomposición Construcción de Vivienda	39
v. Descomposición Construcción de Infraestructura	40

1. Introducción

Existe una variedad de metodologías de predicción que han sido aplicadas exitosamente en los mercados de instrumentos de inversión tales como acciones, bonos, ADRs, pero aún no se ha intentado verificar si estas metodologías pueden aplicarse a otros tipos de mercados.

El objetivo de esta tesis es determinar la existencia de capacidad predictiva en el mercado de los inmuebles de la ciudad de Santiago. Para ello se aplica una red neuronal Ward para predecir cambios en precios de inmuebles - casas o departamentos - en diferentes comunas y áreas geográficas de la capital.

Para probar el objetivo anterior se construye un modelo de media móvil con dos variables explicativas, que predice los cambios del precio promedio de un tipo de vivienda en un área geográfica, en base a los rezagos de las diferencias en la tasa de interés promedio de colocaciones (en adelante TIP) y del Índice Mensual de Actividad Económica (en adelante IMACEC), ambas estadísticas publicadas por el Banco Central de Chile. El promedio de los precios de casas y departamentos en comunas y áreas de la capital fue obtenido de una base de datos de la Cámara Chilena de la Construcción (en adelante CChC).

La presente tesis se estructura de la siguiente forma. El capítulo dos explica el marco teórico bajo el cual se realiza este seminario y la tercera sección presenta los datos y la metodología utilizados. En la cuarta parte se presentan los resultados y la quinta y última sección del trabajo entrega las conclusiones y algunas recomendaciones de investigación futuras.

Adjunta se encuentra la bibliografía utilizada y algunos anexos que facilitan la comprensión del estudio.

2. Marco Teórico

En la actualidad, las ciencias sociales y exactas se encuentran interactuando cada vez con mayor frecuencia. Luego de una marcada tendencia a la división del conocimiento y a la especialización en los últimos quinientos años, desde mediados del siglo pasado científicos y cientistas sociales están nutriéndose en cada vez mayor grado de los avances de otras áreas del conocimiento.

Ejemplos de esta tendencia abundan, como en la biología y la economía, que se han favorecido por avances en las matemáticas y la informática o la física que ha aportado a las finanzas y la geografía, que ha contribuido a la antropología.

El presente trabajo se nutre de una serie de aplicaciones sustraídas de otras áreas del conocimiento. No sería posible escribir este seminario sin los conocimientos estadísticos, informáticos y económicos con los que contamos hoy.

En las finanzas, una rama que se ha desarrollado de forma notoria en las últimas décadas es la administración de inversiones o administración de carteras. La diversificación de los tipos de instrumentos de que dispone el mercado, unido al crecimiento y unificación de los mercados financieros mundiales, han creado una industria financiera de proporciones nunca antes imaginadas.

Básicamente, existen dos formas de analizar los instrumentos financieros para invertir en ellos. Una alternativa es estudiar los fundamentos del instrumento, vale decir, aquellas variables que tienden a afectarlo, formándose un juicio sobre el impacto de estas variables sobre el instrumento. Otra opción es el análisis técnico, que estudia los instrumentos en base a las propiedades estadísticas de su serie de precios. En este caso se pueden aplicar modelos de predicción del precio de un instrumento, asumiendo los más variados modelos con el objeto de representar de forma acertada el comportamiento del valor analizado.

En la práctica, la validez o uso de uno u otro enfoque depende de la relación beneficio-costos de utilizar cada metodología. Para el caso de una acción de una empresa nacional, puede ser más fácil y expedito recolectar información sobre sus *drivers*¹, mientras que para una acción de una empresa tailandesa puede ser más fácil obtener estadísticas de la acción y algunas otras variables. Ambos enfoques son complementarios y probablemente necesarios para un análisis acertado.

¹ Los factores y variables que fundamentan el desempeño real de la compañía.

El análisis técnico, del cual haremos uso en esta tesis, surge porque dentro de la administración de inversiones existe un amplio consenso de que es posible predecir en algún grado las variaciones de los precios de los instrumentos, en base a la información pasada. Eugene Fama, quien en 1970 postulara la Hipótesis de los Mercados Eficientes², ha sido rebatido en muchas ocasiones, encontrándose evidencia a favor de la capacidad predictiva en los mercados accionarios. Esto, en gran parte debido a los costos de adquirir información y concretar transacciones, que Fama suponía inexistentes en su modelo.

Los mercados inmobiliarios, no obstante, no han sido analizados con tanta detención como los mercados de acciones y renta fija. Algunas razones obvias para ello son la baja liquidez de los bienes inmuebles, la heterogeneidad de sus características y los altos costos de información asociados a conocer sus propiedades, que hacen poco atractivo para los inversionistas invertir en inmuebles. Hasta ahora, la mayoría de los estudios provienen de la macroeconomía y analizan las variaciones en demanda y oferta de este sector en función del comportamiento agregado de la economía. No obstante, para un inversionista que esté interesado en destinar parte de sus recursos en este mercado, la información macroeconómica, si bien es útil, no provee detalle suficiente para poder predecir de forma confiable la dirección de las variaciones de corto plazo (menor a un año) de los activos inmobiliarios.

Por otra parte, la información provista sobre el comportamiento del mercado accionario y de renta fija nacional, tampoco entrega una buena aproximación de las variaciones en los precios del mercado inmobiliarios. Mientras las estadísticas sobre el mercado de renta variable y fija se obtienen día a día e incluso *intraday*³, las pocas estadísticas que en el país se manejan sobre el mercado inmobiliario son entregadas mensualmente⁴, con lo que no es posible determinar la correlación entre el mercado inmobiliario y los de renta fija o variable a menos de un mes de plazo. Tampoco existen estadísticas públicas de la venta de inmuebles que además incorporen las diversas características de la vivienda. Solamente es posible establecer relaciones entre variables como la tasa de interés promedio (TIP) mensual, el Índice de Precios Selectivos de Acciones (IPSA) promedio mensual o el Índice Mensual de Actividad

² La hipótesis implica que en un mercado eficiente con cero costos de transacción e información, es imposible predecir el comportamiento de los precios en base a la información pasada porque toda esta información ya está incorporada al precio de hoy.

³ *Intraday* se refiere a variables cuyo comportamiento se mide y observa en períodos menores a un día.

⁴ La Cámara Chilena de la Construcción es el principal órgano recolector de información inmobiliaria.

Económica (IMACEC), con valores promedio del mercado de la vivienda que pudieran recolectarse de empresas e instituciones privadas.

i. El Mercado Inmobiliario

El mercado de la construcción es un componente sumamente importante y dinámico dentro de la economía nacional. Entre los años 2001 y 2005, la construcción –que agrupa la edificación de metros cuadrados de vivienda así como infraestructura– representó en promedio un 8,6% del Producto Interno Bruto (en adelante PIB) desglosado por clase de actividad económica, una cifra no despreciable si se considera que el mayor componente del PIB, la industria manufacturera, representó el 17,1%. Esto sitúa la construcción en el quinto puesto en tamaño relativo dentro del PIB, de un total de trece clases de actividad económica. El año 2006, la construcción aportó 8.500 millones de dólares a un PIB de 120.633 millones de dólares⁵.

En términos de ventas, estimaciones de la Cámara Chilena de la Construcción (CChC) sitúan el tamaño del mercado de la construcción en \$15.500 millones de dólares, de los cuales el 34% corresponde a vivienda, que alcanza los \$5.270 millones de dólares en ventas. De este monto, el 90% corresponde a vivienda privada y el 10% restante a vivienda social. Además se estima que existen alrededor de 500 empresas de construcción (de infraestructura y vivienda), por lo que la oferta en este mercado está sumamente fragmentada.

Por otra parte, Chile arrastra un déficit histórico en la construcción de vivienda debido a su condición de país en desarrollo. Si bien la pobreza se redujo de un 39% en 1990 a un 21% en 2000, la gran cantidad de personas sin hogar nos puede dar un indicio de la enorme cantidad de familias e individuos que aspiran a tener una vivienda, sea propia o arrendada. En efecto, para el año 2004 el Instituto Nacional de Estadísticas (en adelante INE) calculó el déficit habitacional de Chile en 543.542 viviendas⁶. Por ello, no es de extrañar que las tasas de crecimiento del sector construcción sean en promedio mayores a las de la economía. Asimismo, la tendencia a crear hogares cada vez más pequeños e incluso de un sólo individuo, también

⁵ Fuente: Instituto Nacional de Estadísticas (INE), ajustando a pesos y tipo de cambio de 2006, considerando participación de la construcción en el PIB en base al total de las trece clases de actividad económica tipificadas por el INE.

⁶ Fuente: INE.

impactan positivamente en la demanda por vivienda, dado que cada vez más miembros de una familia deciden mudarse y crear su propio hogar.

Por ello, mientras el PIB creció a una tasa promedio de un 4,5% entre 2002 y 2006, el sector construcción lo ha hecho a una tasa del 4,9%, es decir, un 9,5% más que la economía nacional. Esta tendencia a que la construcción de inmuebles crezca más que el PIB seguramente continuará por al menos una década, toda vez que el aumento de la riqueza de las familias de estratos socioeconómicos bajos les permita acceder a su primera vivienda.

ii. Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (RNA) son sistemas computacionales que intentan imitar el cerebro humano, hasta en su capacidad de "aprendizaje". En otras palabras, uno puede entrenar o "educar"⁷ a una red neuronal mostrándole todas las variables que influyen en un problema y sus respectivos resultados y la red neuronal irá probando distintas relaciones matemáticas o ponderadores para cada variable dependiente, hasta encontrar la relación que mejor se ajuste o que minimice el error de la predicción. Esto se puede lograr gracias a que a la red se le muestran no sólo las variables independientes sino que también las dependientes que han ocurrido en el pasado. Después se puede probar lo que la red ha "aprendido" mediante un grupo de datos de prueba, donde nuevamente se le muestran tanto las variables dependientes como las independientes que han ocurrido en el pasado, pero esta vez la red no va adaptando sus ecuaciones, sino que aplica la ecuación o relación a la que llegó en la etapa de aprendizaje y compara el resultado que obtiene con el que se dio en la realidad, pudiendo medir de esta forma qué tanto se alejan en promedio las predicciones de la red de lo que ocurre en la realidad. Si el analista queda satisfecho con la calidad de ajuste que ha logrado la red, puede proceder a aplicar la red neuronal a otro grupo de datos que nunca ha visto, solo que esta vez a la red neuronal se le entregarán únicamente las variables independientes, a partir de las cuales deberá predecir las dependientes.

⁷ Los conceptos de "educar" una red porque ésta tiene capacidad de "aprender" provienen del lenguaje de la informática. Matemáticamente hablando, esta capacidad de las redes no es otra cosa que la de hallar los estimadores óptimos mediante minimizaciones de la suma del error cuadrático.

Para el desarrollo de esta tarea la red neuronal está compuesta de varias capas, las que a su vez están compuestas de varias neuronas. Cada neurona se "reparte" una porción del problema con lo que son capaces de trabajar al mismo tiempo con la porción que le corresponda. Además, las neuronas de una capa pueden generar *inputs* para las neuronas que vienen en las capas posteriores. Esto dependerá de la cantidad de capas que posea la red neuronal.

Básicamente las redes neuronales tienen una capa de entrada con una cantidad de neuronas igual a la cantidad de *inputs* del problema, luego una o más capas ocultas que poseen la cantidad de neuronas que el analista estime conveniente y finalmente hay una capa de salida que posee sólo una neurona. La capa de entrada recibe los datos y los reparte entre las neuronas de la primera (y a veces única) capa oculta, sin mayor procesamiento de los datos más que la posible aplicación de una función escalar. Luego los datos entran a las capas ocultas donde son procesados y se les aplica una función de activación, definida por la persona que aplica la red para cada capa oculta. Después de pasar por las capas ocultas, todos los datos llegan a la capa de salida, donde se procesan los datos y se entrega como *output* la respuesta buscada.

a) Sistemas Paralelos, Distribuidos y Adaptativos⁸

Existen tres características fundamentales del sistema nervioso humano que las RNA buscan imitar: Poder formular varios cálculos a la vez de forma paralela, poder distribuir la memoria disponible y ser capaz de adaptarse al entorno.

El Procesamiento paralelo es esencial si se quiere imitar al sistema nervioso humano, ya que el hombre es capaz de procesar varios datos al mismo tiempo, lo que le permite entender las cosas de forma mucho más rápida que si tuviera que ir interpretando lo que sucede en su entorno un paso a la vez, por ejemplo, las neuronas de la visión (los conos y bastones de la retina) se "reparten" la visión, encargándose cada una de una porción pequeña de lo que el ojo alcanza a ver. De la misma forma la red neuronal reparte distintas "porciones" del problema entre todas sus neuronas o procesadores elementales, con lo que logra procesar los datos y encontrar una solución de forma más rápida.

⁸ Extracto del primer capítulo del libro "Redes neuronales y sistemas borrosos" de Martín del Brío y Alfredo Sanz Molina.

Otro concepto importante es el de la memoria distribuida. En un computador la información se almacena en posiciones o lugares físicamente bien definidos (o sea se le asigna un espacio en el disco duro o en la memoria temporal). Sin embargo, en los sistemas neuronales la información se distribuye según las conexiones de la red (o sinapsis, que es como se denominan las conexiones entre neuronas). De esta forma, si una conexión se daña solo se perderá una pequeña fracción de la información. Además, los sistemas neuronales biológicos son redundantes, de forma que muchas neuronas y sinapsis pueden realizar un papel similar; o sea, el sistema tolera fallas.

La tercera característica primordial es la de la adaptabilidad. Las RNA poseen una gran variedad de mecanismos para adaptarse a su entorno o para “aprender” según las influencias que recibe del exterior. La forma más común que tienen las RNA para adaptarse es mediante la modificación de sus sinapsis (conexiones entre neuronas), lo que les permite aprender de la experiencia. Esto les permite generalizar a partir de casos particulares. Así, podemos hablar de las RNA como sistemas paralelos, distribuidos y adaptables.

b) La Neurona

Como ya se puede desprender de lo leído anteriormente, la neurona es la estructura básica de las redes neuronales. Éstas, intentan imitar a las que tenemos en el cerebro, recibiendo impulsos desde varias fuentes, procesando los impulsos y retransmitiendo sus propios impulsos a otras neuronas o a los receptores finales de la información (como los músculos por ejemplo). De esta misma forma, las neuronas que componen las RNA pueden recibir información desde varias fuentes a la vez, aplicarles una función matemática y posteriormente traspasar sus resultados a otras neuronas o al analista que está esperando los resultados.

En la Figura 2 se puede apreciar la estructura de una neurona biológica típica. En este diagrama se aprecian sus partes funcionales básicas. La neurona

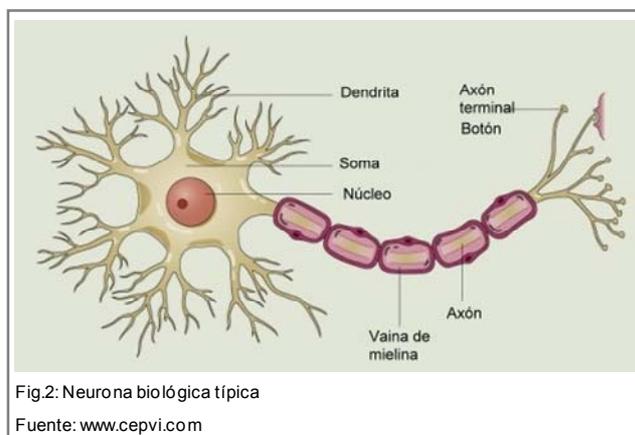
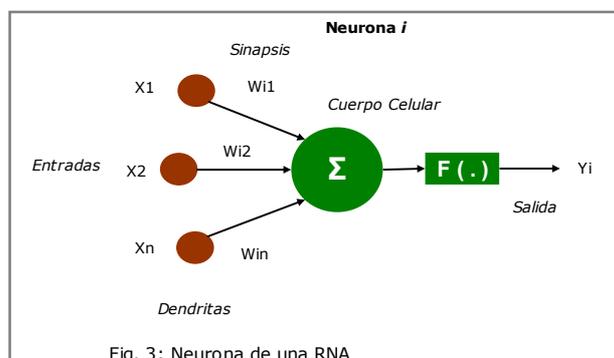


Fig.2: Neurona biológica típica
Fuente: www.cepvi.com

recibe impulsos eléctricos desde otras neuronas o directamente desde el exterior a través de sus dendritas por un proceso denominado "sinapsis". Gracias a que posee gran cantidad de dendritas puede recibir información de varias fuentes a la vez. Luego los impulsos llegan al soma, que es el lugar donde se procesan estos impulsos y se sintetiza la información recibida en un solo impulso que viajará por el axón hasta los botones terminales, donde el impulso puede ser traspasado a las dendritas de otra neurona o directamente a un músculo si se trataba de una neurona motora. Así los impulsos nerviosos viajan a la velocidad de la luz desde el lugar donde se generan hasta su destino a través de miles de neuronas, cada una con una función específica.

En la Figura 3 se puede ver un diagrama básico de una neurona o "Procesador Elemental" (PE) de una RNA. Ahora es fácil apreciar la similitud entre las neuronas biológicas y los PE de las RNA. Tenemos que la neurona recibe información desde distintas fuentes, esta vez, la



información consistirá de datos provenientes de otras neuronas. A cada dato le asignará un peso (W_{ij}) que podrá tomar valores entre 1 y -1, este dependerá de la intensidad de interacción entre la neurona que genera el dato y la que lo recibe, el valor del peso dependerá de:

- Si la neurona precedente (neurona i) incentiva la activación de la neurona que recibe la información (neurona j), entonces la conexión es excitatoria ($w_{ij} > 0$).
- Si la neurona precedente (neurona i) desincentiva la activación de la neurona que recibe la información (neurona j), entonces la conexión es inhibitoria ($w_{ij} < 0$).
- Si la neurona precedente (neurona i) no ejerce efecto alguno sobre la activación de la neurona que recibe la información (neurona j), entonces la conexión es llamada "inactiva" ($w_{ij} = 0$).

Luego, mediante la regla de propagación que haya definido previamente el usuario de la RNA. La neurona tomará todos los datos recibidos y les calculará un valor neto (llamado entrada neta). La forma más común que toma esta regla es la de una suma ponderada de los datos por sus pesos respectivos, con lo que queda:

$$\sum_j w_{ij} x_j$$

Donde X_j es el dato que proviene de la neurona "j". Luego a esta suma ponderada se le aplicará la función de activación ("F (.)" en la figura 3) que el programador le haya asignado a la capa a que pertenece esa neurona. Así la neurona generará un *output* de:

$$Y_i(t) = F_i \left(\sum_j w_{ij} x_j \right)$$

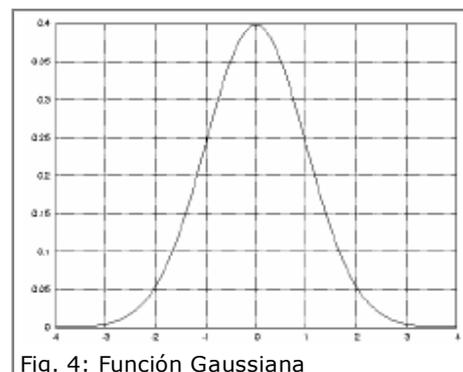
El que servirá de entrada para una o más neuronas posteriores o si la neurona era parte de la capa de salida, entregará el resultado de la red.

c) Funciones de Activación

Las funciones de activación son otra parte fundamental de las redes neuronales, constituyendo la forma en que las neuronas manipularán los datos que reciban para generar la información que le transmitirán a la siguiente capa de neuronas o al analista si forman parte de la capa de salida. Las funciones de activación son definidas por el usuario de la red y se le asigna a cada capa de neuronas una función de activación.

Existen infinitos tipos de funciones de activación posibles, las que se usen dependerán de cómo quiera el usuario que la red manipule los datos o de qué importancia le dará a distintos tipos de éstos. Por ejemplo, si se usa una función identidad o lineal, donde $y = x$ ó $F(x) = x$, el analista le estaría dando la misma importancia a todos los datos. Otro tipo de función podría ser de tipo "escalón" en la que la neurona no generará información a menos que la entrada neta de información alcance un cierto "umbral".

Algunas de las funciones más utilizadas en las capas de entrada y salida de una red neuronal son las funciones Gaussiana y su complemento, y la función Tangente Hiperbólica. Para fines de esta investigación nos interesarán las tres de estas funciones, ya que serán éstas las utilizadas en la construcción de la red.



La función Gaussiana, no es más que la muy conocida función de distribución normal o también llamada "campana de Gauss" que podemos ver en la figura 4. Esta función es monótona creciente y se usa cuando se cree que la información del centro o cercana a la media es la más relevante, por lo que se concentra en detectar diferentes características en este rango de datos. Además entrega datos de salida dentro del rango (0,1). La fórmula de la función de distribución Gaussiana es:

$$F(x) = e^{-x^2}$$

La función Complemento de Gaussiana es la inversa de la función Gaussiana, o sea, es una campana de Gauss "de cabeza", como muestra la figura 5. Esta función le asigna más importancia a los datos de las colas o de los extremos de la distribución, como se puede ver en el gráfico. Su expresión matemática es muy similar a la función Gaussiana y es:

$$F(x) = 1 - e^{-x^2}$$

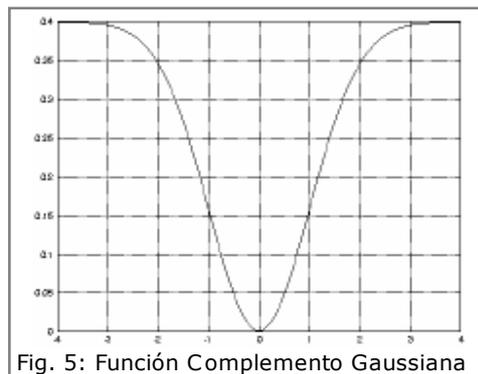


Fig. 5: Función Complemento Gaussiana

Al usar estas dos funciones en dos *slabs*⁹ distintos dentro de la capa oculta, se logra que la capa de salida tenga dos perspectivas de los datos. Al combinar los dos puntos de vista de las características de los datos, se puede lograr una mejor predicción.

Adicionalmente a estas dos populares funciones, la red que utilizaremos cuenta con la función Tangente Hiperbólica, que también es una función monótona creciente, pero con la diferencia de que su rango de salida está acotado entre (-1,1). Combinando las tres funciones (la Tangente Hiperbólica en las capas de entrada y salida y las Gaussiana y Complemento de Gaussiana en las capas ocultas) podemos asegurar mejores resultados. En la figura 6 podemos observar una función Tangente Hiperbólica, cuya función se define como

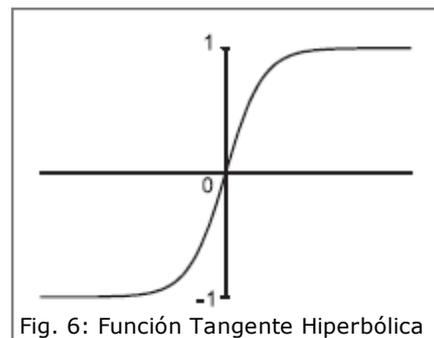


Fig. 6: Función Tangente Hiperbólica

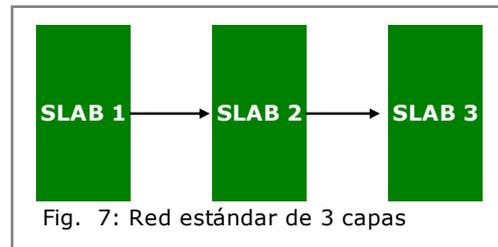
⁹ Un *slab* es un conjunto de neuronas que pertenecen a la misma capa y usan la misma función de activación. Puede existir más de un *slab* dentro de cada capa. De hecho en esta tesis la capa oculta poseerá dos *slabs*, como se verá más adelante.

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

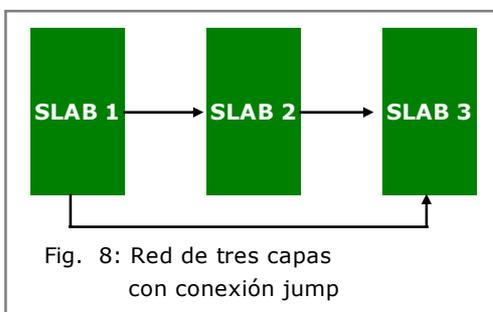
Luego, la función Tangente Hiperbólica es una función que “estandariza” la escala de los datos en la capa de entrada, para que las capas ocultas los procesen. Las dos capas ocultas son las que procesan los datos y posteriormente los entregan a la capa de salida, que es nuevamente una función Tangente hiperbólica.

d) Arquitectura de RNA

La arquitectura de una RNA constituye la forma en que están distribuidas las neuronas, grupos de neuronas (*slabs*), capas y cómo están conectadas e interactúan entre sí. También definirán como fluye la información a través de la red. La forma en que están



conectadas las neuronas determinará la forma en que se comporte la red, por lo que la arquitectura es una característica fundamental de la RNA que se use en distintos estudios.



Existen muchos tipos distintos de arquitecturas para redes neuronales, pero entre las más populares se encuentran las redes tipo estándar como la de la figura 7 que posee 3 capas. Otro tipo popular de RNA son las que tienen conexiones de tipo *jump* (salto en inglés), como la que aparece en la figura 8, del

esquema se puede ver que se les llama conexiones *jump* debido a que hay conexiones entre capas que no son sucesivas en la red.

Un tercer tipo de redes más comúnmente usadas son las de Jordan – Elman ilustrada en la figura 9. Una particularidad de estas redes es que los grupos de neuronas se pueden “realimentar” con su propia información o con la información de una capa paralela. Se puede ver que en este tipo de redes la capa de entrada tiene dos *slabs* de neuronas, o sea que hay un *slab* extra. Esto le permite a la red ver el conocimiento anterior que tenía sobre las entradas anteriores.

El cuarto tipo de arquitectura que deseo mencionar es la red polinomial GMDH (Group Method of Data Handling) o la red polinomial de Método de Manejo Grupal de Datos que se puede ver en la figura 10. Esta red va construyendo capas sucesivas con conexiones complejas que constituyen los términos de un polinomio. Estos términos del polinomio son creados a partir de regresiones lineales y no lineales, que se van generando en cada capa a partir de los resultados obtenidos de las capas anteriores.

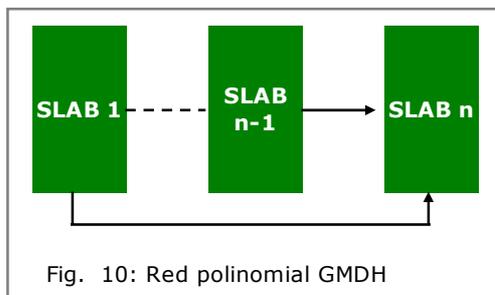


Fig. 10: Red polinomial GMDH

detectar diferentes características en los patrones procesados a través de la red. Así se pueden aplicar las funciones de activación Gaussiana y complemento de Gaussiana, que mencionamos anteriormente, dentro de la misma capa oculta, logrando que la capa de salida tenga diferentes puntos de vista de los datos, como también se dijo con anterioridad.

Las redes aquí presentadas son sólo unos pocos ejemplos de los muchos tipos de arquitecturas de redes y muchas variaciones posibles que han sido propuestos anteriormente.

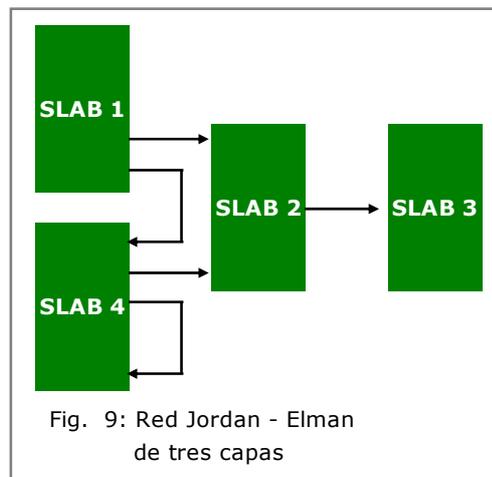


Fig. 9: Red Jordan - Elman de tres capas

El último tipo de red que nos interesa es la red "Ward", que será la red usada en este trabajo. Como se aprecia en la figura 11, la red Ward permite tener más de un slab de neuronas en las capas ocultas. Con esto se le pueden aplicar distintas funciones de activación a cada slab de la capa oculta, lo que permite

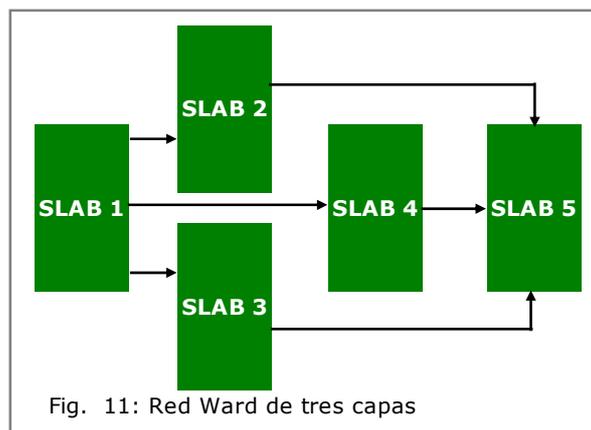


Fig. 11: Red Ward de tres capas

e) Proceso de Aprendizaje

Como ya dijimos, las redes neuronales "aprenden" relaciones entre distintas variables a partir de la identificación de patrones observables en datos pasados.

La forma más común de "aprendizaje" y también de adaptación, que tienen las redes neuronales es a través de la modificación de los pesos (W_{ij}) que cada neurona le asigna a la información que recibe de las neuronas que la preceden.

Así, las RNA van modificando los pesos en la etapa de entrenamiento para ir reduciendo el error que cometen al tratar de predecir las variables independientes.

Como se dijo antes, en la etapa de entrenamiento las redes neuronales van calculando sus predicciones de las variables requeridas por el usuario y cada vez que llegan a un valor lo comparan con el valor real que tuvo la variable que se intentó predecir, así la red ve que tanto se equivocó y modifica los pesos sinápticos (W_{ij}) para tratar de disminuir ese error. Para esto la red neuronal puede partir con pesos iguales a cero ($W_{ij} = 0$) o asignar pesos de forma aleatoria antes de empezar a "aprender", así tiene un punto desde donde empezar a adaptar los pesos. Una forma muy común de ir modificando los W_{ij} es mediante una distribución proporcional del error cometido en la predicción entre todas las neuronas según el aporte de cada una al resultado final, o sea, mientras más aportó la neurona o conexión al resultado, mayor parte del error se le asignará a ella para modificar sus pesos.

En su libro "Redes neuronales y sistemas borrosos" Bonifacio Martín del Brío y Alfredo Sanz Molina definen el proceso de aprendizaje como: "...proceso por el que se produce el ajuste de los parámetros libres de la red a partir de un proceso de estimulación por el entorno que rodea la red. El tipo de aprendizaje vendrá determinado por la forma en la que dichos parámetros son adaptados. En la mayor parte de las ocasiones el aprendizaje consiste simplemente en determinar un conjunto de pesos sinápticos que permita a la red realizar correctamente el tipo de proceso deseado."

Otra forma de aprender o adaptarse de las redes neuronales es a través de la creación o destrucción de neuronas, en el que la red sufre un cambio de su propia arquitectura.

f) Generalización Versus Memorización

El gran atractivo del aprendizaje de las RNA es que puedan generalizar a partir de ejemplos, lo que constituye una de las características fundamentales de las redes neuronales. Esta característica permite que las RNA puedan generar datos confiables con datos que no han visto con anterioridad a partir de lo que han aprendido de la información pasada que se les entregó en el período de aprendizaje.

Pero al esforzarse por reducir el error (medido por el Error Cuadrático Medio o ECM) que comete en la etapa de aprendizaje, puede que la red memorice los patrones de la fase de entrenamiento, con lo que la red serviría sólo para predecir valores para ese conjunto de datos y no para datos que no ha visto nunca.

Por ejemplo, si dejamos que la red haga todas las iteraciones que sean necesarias hasta obtener un $ECM = 0$ en la etapa de entrenamiento, la red se ajustará perfectamente a estos datos, pero quizás cuando le presentemos datos nuevos, su ajuste será pésimo. De hecho ya se han llevado a cabo experimentos para probar esto

y se ha llegado a determinar que a medida que aumentan las iteraciones hechas en la etapa de entrenamiento, el error de la fase aprendizaje y el error de la etapa de prueba (o test) disminuyen juntos en una primera etapa, pero después de cierto punto el error de la etapa de prueba empieza a crecer nuevamente en circunstancias que el

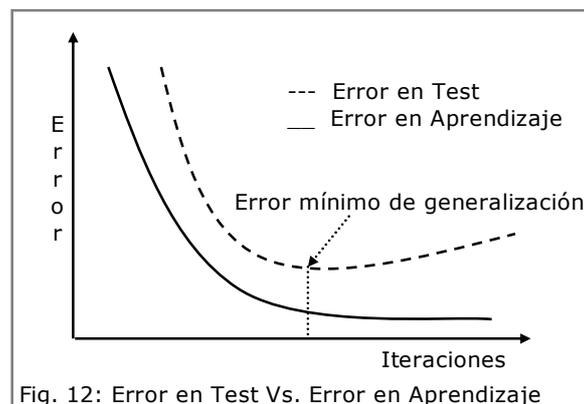


Fig. 12: Error en Test Vs. Error en Aprendizaje

ECM para el conjunto de entrenamiento sigue disminuyendo, como muestra el gráfico de la figura 11. Es por esto que por lo general se usa un conjunto de datos para entrenar la red y otro conjunto distinto para probar qué tan buen ajuste posee. Así, el ECM de la red usando los datos de prueba es un buen indicador de la capacidad de generalización que posee la red o de cuánto memorizó los datos de entrenamiento.

g) Síntesis sobre Redes Neuronales

Como mencionábamos anteriormente, las redes neuronales son sistemas paralelos, distribuidos y adaptativos que buscan imitar el cerebro humano en sus características fundamentales, sobre todo en el aspecto de lograr aprender relaciones sobre distintas variables a partir de información histórica. Para lograr esto, las RNA se componen de¹⁰:

- Un conjunto de procesadores elementales o neurona artificiales. (Que procesarán la información)
- Un patrón de conectividad o arquitectura. (Que determinará el orden y la forma en que se procese la información)
- Una dinámica de activaciones. (Que determinará cómo se tratará la información y qué importancia se le otorgará a cada tipo)
- Una regla o dinámica de aprendizaje. (Que determinará qué tan buena es la red para generalizar a partir de ejemplos pasados)
- El entorno donde opera. (Que influenciará la forma en que la red se adapte o aprenda de los datos que se le entreguen).

Esta es una "pincelada" de lo que son las redes neuronales. Esta reseña está enfocada principalmente a este trabajo de investigación y sus necesidades. Para una profundización del tema recomiendo el libro "Redes neuronales y sistemas borrosos" de Bonifacio Martín del Brío y Alfredo Sanz Molina, de la editorial RA – MA.

¹⁰ Según D.E. Rumelhart y J.L. McClelland del Parallel Distributed Processing Research Group de la Universidad de California en San Diego.

3. Metodología

El objetivo de este seminario es probar la existencia de capacidad predictiva en el mercado inmobiliario chileno. Se busca determinar si el signo de los cambios en el precio promedio de un conjunto de viviendas con ciertas características en común (área geográfica, casa o departamento) puede ser predicho con la ayuda de variables explicativas. La base de datos utilizada para recrear la variable dependiente fue obtenida de la CChC, que facilitó su índice promedio del precio del metro cuadrado de las viviendas de distintos sectores de la capital, para el desarrollo de este trabajo. Las variables explicativas utilizadas son la TIP de colocaciones de 90 a 365 días y el IMACEC¹¹. Estas variables son publicadas mensualmente por el Banco Central de Chile y están disponibles en la página web del instituto emisor¹².

Los programas elegidos para calcular el modelo fueron Microsoft Excel 2003 y Visual Basic 2003, de la Compañía Microsoft. En Excel se realizaron todos los cálculos y en Visual Basic se programaron las macros¹³ que ejecutaban el cálculo del modelo.

i. Los Datos

Los datos de precios de inmuebles utilizados corresponden a una base de datos facilitada por la CChC, principal entidad recolectora y procesadora de información inmobiliaria en el país. La base consta del número de viviendas ofrecidas mensualmente en distintas comunas o grupos de comunas en el país, el precio promedio en UF de estos inmuebles y los metros cuadrados promedio de las viviendas ofrecidas. Consta de series de precios de casas para once comunas del Gran Santiago y de departamentos en diecisiete comunas o sectores de la ciudad. Los datos tienen una frecuencia mensual y se extienden de enero de 1994 hasta abril de 2007, totalizando 160 observaciones. Por desgracia, la minoría de las series están completas

¹¹ El IMACEC es una medida similar a la del PIB, pero de frecuencia mensual. Es menos detallada que el PIB (incluye menos componentes) pero tiende a ser prácticamente idéntico si agregamos los IMACEC de un año y lo comparamos con el PIB correspondiente. Es la mejor estimación de la actividad económica en plazos menores de un trimestre.

¹² www.bcentral.cl

¹³ Archivos que entregan listas de comandos a Excel, para que realice las acciones que se le solicita, cada vez que el usuario ejecute la macro.

y sólo cinco series de casas y siete series de departamentos presentan precios a través de todo el período¹⁴.

Son estas cinco series de casas y siete de departamentos las cuales utilizaremos en la aplicación de nuestro modelo.

Cabe señalar que los precios entregados por la CChC son de oferta y no son precios de transacciones. Es decir, son los precios a las que las inmobiliarias ofrecen en primera instancia las viviendas. Dado que con frecuencia los precios de compraventa se acuerdan con un pequeño descuento (por ej. 5% por pago al contado), podemos suponer que probablemente estén por sobre el precio de equilibrio del mercado, aunque podemos asumir razonablemente que este porcentaje se mantiene constante en el tiempo, con lo cual no sería necesario ajustar los precios para nuestro análisis. Este sesgo en el valor del precio de los inmuebles no debiera generar alteraciones graves en nuestras predicciones. En otras palabras, los precios padecen probablemente de un seso positivo pero para predecir el signo del cambio en los precios, esta diferencia no debiera ser relevante, asumiendo que permanece constante a través del tiempo en una serie determinada.

Nuestra variable dependiente es, además, un promedio del precio del metro cuadrado de la vivienda (casa o departamento) en un sector acotado de la capital, expresado en UF. Esta característica la hace parecerse más a una especie de índice que al valor de un instrumento financiero, dado que depende de los precios de las diferentes unidades que lo componen.

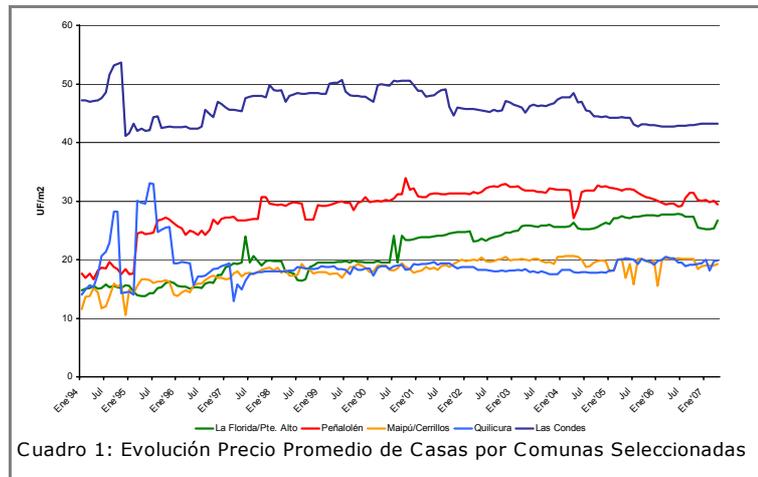
Otra limitación de nuestra base de datos es que no incluye a todos los proyectos desarrollados en las áreas geográficas señaladas. Esto se debe a que no todas las empresas inmobiliarias están afiliadas a La Cámara, y que no están obligadas a reportar su oferta de viviendas. Esto implica que, si bien más del 50% de los proyectos de las comunas están incluidos en nuestras estimaciones, existen una serie de empresas que sí tienen un importante número de proyectos en ciertas comunas y que no los reportan, por lo que podría existir un sesgo en nuestra base de datos. En la práctica, esto podría significar truncamiento en nuestras estimaciones, con los consiguientes problemas de sesgo por variable omitida. En el presente trabajo no nos

¹⁴ Las series de casas son: La Florida - Puente Alto, Puente Alto, Maipú - Cerrillos, Peñalolén, Quilicura, Las Condes, Lo Barnechea, La Reina, Vitacura, Huechuraba, San Bernardo. Las Series de departamentos son: Providencia, Las Condes, Lo Barnechea, Colón, El Golf, Vitacura, Ñuñoa, Macul, Centro, San Miguel, Puente Alto - San Bernardo - La Cisterna, La Florida, Maipú, Recoleta, Independencia - Conchalí, Estación Central - Renca - Quinta Normal, La Reina.

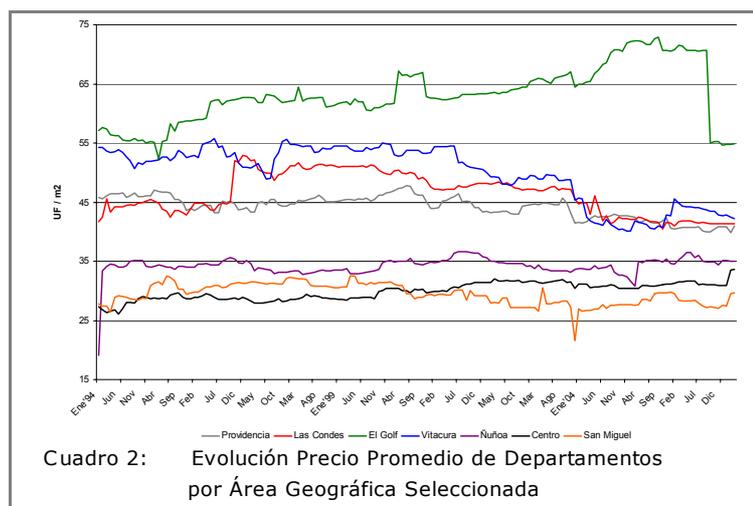
ocuparemos de modelar el truncamiento, pero queremos dejar constancia que nuestra capacidad predictiva posiblemente esté afectada por este problema.

Otro punto muy importante de la base de datos es que, a diferencia de los precios de un bien o instrumento financiero específico, nuestra variable dependiente depende de sus componentes y estos componentes no tienen características homogéneas a través del tiempo y a través de las áreas geográficas. Un departamento en una comuna de ingresos altos está más equipado que un departamento en una comuna con ingresos medios, dado que los demandantes tienen otras disposiciones a pagar. Si bien este efecto queda parcialmente aislado al separar el precio de las viviendas por comuna, aún existe el riesgo de que las comunas, a través del tiempo, cambien su población, desde la perspectiva de sus ingresos, lo cual podría impulsar la construcción de diferentes tipos de vivienda. Esto implicaría en la práctica que nuestra serie de datos no está controlando el cambio en la calidad de las viviendas de un periodo a otro. Eso implica que posiblemente el costo de adquirir una vivienda con las características de las viviendas vendidas en el primer periodo de nuestra base sería mucho menor hoy en día, dado que la construcción y el equipamiento de las viviendas se han incrementado. Si quisiéramos controlar por este "efecto tecnología" en la práctica tendríamos que tener información detallada de las características de las viviendas vendidas a través del tiempo y controlar por ellas. Por desgracia, esta información no está disponible. También podríamos simular datos con características homogéneas a través del tiempo, pero en ese caso necesitaríamos una estimación de cuál es el cambio mensual del incremento tecnológico utilizado en las viviendas y al asumir ese valor, el remedio podría ser mucho pero que la enfermedad, prefiriéndose no corregir este posible sesgo.

Los cuadros 1 y 2 presentan los precios promedio de los inmuebles para aquellas comunas en que las series están completas desde enero de 1994 hasta abril de 2007.



Al analizar las series, es fácil reconocer cambios abruptos en el precio de alguna serie en particular y que no guarda relación con la magnitud de los cambios de otras series. Tal es el caso de la serie de departamentos de El Golf entre los periodos septiembre y octubre de 2006. En los precios de las casas, llama la atención la caída y posterior recuperación abrupta de la serie de Quilicura entre octubre de 1994 y marzo de 1995. También se observa un desplome del precio de las casas en Las Condes, entre octubre y noviembre de 1994, aunque en este caso la serie no vuelve a recuperarse. Estos cambios probablemente se deban a errores en la construcción de la base de datos, cambios en el plano regulador de las comunas o inclusión/omisión de partes de la comuna o de empresas constructoras de calidad de vivienda diferente.



Por otra parte, hemos incluido como variables explicativas independientes el IMACEC de cada periodo así como la Tasa de Interés Promedio para Colocaciones a 90-365 días en UF reajutable (TIP). Estas series son publicadas por el Banco Central mensualmente y están disponibles para todo el periodo de la muestra.

El IMACEC es el indicador mensual de actividad económica más detallado que se computa en Chile. Para nuestro análisis puede ser interpretado como un Proxy de la demanda por vivienda, dado que a mayor actividad económica habrá mayores ingresos y posiblemente mejores expectativas con respecto al desempeño económico futuro, lo cual incide de forma positiva en la demanda, de viviendas. Además, un componente del IMACEC es también el sector construcción, por lo que alrededor del 9% del IMACEC vendrá explicado por esta área de la economía.

La TIP es un indicador promedio computado en base al costo de endeudamiento a un plazo de al menos 90 días y por un máximo de 365 días, en UF reajutable. Esta variable representa el mejor Proxy para el costo de endeudarse para adquirir viviendas, así como para financiar su construcción. Es decir, un alza de la TIP impacta negativamente tanto a la oferta como a la demanda por inmuebles. Además está expresado en UF, que es la moneda (o índice) comúnmente utilizado para los créditos hipotecarios.

ii. RNA Utilizada: Ward

El modelo aplicado para realizar la predicción es una RNA Ward. Si bien este tipo de redes es recomendado para la predicción de variables financieras (Parisi, Parisi y Guerrero, 2003) no hemos encontrado estudios que apliquen RNA a la predicción de inmuebles, por lo que se desconoce si otros modelos podrían generar mejores predicciones para este tipo de datos.

Con esta red podemos utilizar varias funciones a la vez en sus distintas capas, lo que potenciará nuestras predicciones.

La red Ward empleada, que por su arquitectura nos permite usar varias funciones en sus capas ocultas, consta de una capa de entrada y de salida con funciones Tangente Hiperbólica y dos capas ocultas que dotamos con las funciones Gaussiana y Complemento de Gaussiana. Esta estructura permite centrar la atención

de nuestra estimación en los datos centrales, dotándolos de mayor relevancia que los valores extremos.

El modelo que la RNA busca predecir es:

$$\alpha_i * \Delta TIP_{i-1} + \beta_{2,i} * \Delta TIP_{i-2} + \gamma_i * \Delta IAE_{i-1} + \delta_i * \Delta IAE_{i-2} = \Delta P_i$$

$$\forall i = 1 \dots 159$$

en donde α_i , β_i , γ_i , δ_i son los parámetros a estimar, ΔTIP_{i-1} es la diferencia de la TIP rezagada en un período, ΔTIP_{i-2} es la diferencia de la TIP rezagada en dos períodos, ΔIAE_{i-1} es la diferencia del IMACEC rezagada en un período y ΔIAE_{i-2} es la diferencia del IMACEC rezagada en dos períodos.

Tal como mencionábamos en la parte 3, la RNA de preferencia se utiliza sobre un conjunto de datos para "entrenarla" y luego se aplica a un segundo grupo de datos, con objeto de medir su capacidad de generalización. Por ello, nuestra muestra se subdividió en dos partes iguales: La primera mitad es nuestro período intramuestral y sirve para que la red "entrene", la segunda mitad corresponde a nuestra submuestra extramuestral, para que el modelo prediga en base a lo "aprendido" sobre nuevos datos.

iii. **Rolling Vs. Recursivo**

Al establecer la ventana de errores que la red deberá minimizar, podemos optar por una ventana recursiva o *rolling*. La diferencia es que con una ventana recursiva, estaremos incluyendo todos los errores de los periodos anteriores en la proyección del cambio en el precio del inmueble. En cambio, la ventana *rolling*, como lo dice el nombre, se desplaza a través del modelo, incluyendo siempre la misma cantidad de errores cuadráticos medios pasados, pero eliminando el primer error considerado y agregando el último error calculado a medida que el modelo avanza en su estimación.

En esta tesis preferimos utilizar una ventana *rolling*, dado que éstas arrojan mejores resultados en la predicción de variables financieras (Parisi, Parisi y Guerrero, 2003). Nuevamente, queda por determinar si una estimación hecha con una ventana recursiva hubiese podido superar nuestra estimación con *rolling*.

La manera en que el programa computacional realiza la minimización del error cuadrático medio es iterando miles de veces, probando con distintas combinaciones de estimaciones para nuestros parámetros. Técnicamente esta metodología tiene la ventaja de no quedar atrapada en mínimos locales, que es lo que puede suceder si la estimación la realizáramos con Solver o SuperSolver¹⁵. La desventaja de usar modelos aleatorios es que se requiere de muchas iteraciones y, por ende, tiempo y buenos procesadores. Para efectos de esta tesis, se utilizaron en primera instancia cien mil iteraciones. Dado el tiempo que estas iteraciones requerían, posteriormente se disminuyó su número a diez mil.

iv. Validación de los Resultados

El output de nuestra red Ward no es el resultado final de todo nuestro análisis. Para poder analizar si la red predijo correctamente el signo del cambio en precios de un periodo a otro, calculamos el porcentaje de predicción de signo (en adelante PPS)¹⁶, que no es otra cosa que el número de veces que la RNA predijo correctamente el signo del cambio en precio dividido por el número total de predicciones realizadas. Para determinar nuestros PPS extramuestrales, consideramos sólo aquellos modelos que arrojaban un PPS intramuestral superior al 60%. Esto, con el objeto de que nuestros modelos estén equilibrados en el sentido de tener un mínimo de predicción intramuestral (que mide buena capacidad de memorización) y un buen PPS extramuestral (que mide una buena capacidad de generalización).

Una vez obtenidos estos resultados, comparamos la rentabilidad que obtendríamos si siguiéramos el modelo con la rentabilidad que obtendríamos de una técnica de comprar al comienzo de la serie y vender en el último período, también conocida como *Buy & Hold*. No es poco frecuente obtener modelos con alta capacidad de predicción pero malos resultados prácticos, por lo que esta comparación resulta imprescindible.

¹⁵ Solver y SuperSolver son programas complementarios de Excel que permiten optimizar sistemas de ecuaciones, entregando máximos o mínimos.

¹⁶ El PPS se calcula como la suma de todos los cambios de signo correctamente predichos sobre el total de predicciones realizadas. De acuerdo a Leung, Daouk & Chen (2000), los modelos que predicen el cambio de signo se desempeñan mejor que aquellos modelos que predicen valores de precios.

Además, realizamos un test de Acierto Direccional, construido por Pesaran y Timmermann (1992), que busca probar si existe capacidad de predicción de signo, sin importar la magnitud de las proyecciones.

Lo que este test realiza es probar si existe independencia entre las proyecciones y los valores reales. Si se rechaza, entonces quiere decir que no existe independencia y por lo tanto nuestro modelo sí está prediciendo. Si no se rechaza, no hay evidencia a favor de la capacidad predictiva.

La fórmula del test es:

$$DA = \frac{SR - SRI}{\sqrt{Var(SR) - Var(SRI)}}$$

Donde SR y SRI se definen como:

$$SR = PPS = \frac{\text{Cantidad de Signos Acertados}}{\text{Número total de predicciones}} = \frac{\sum_{i=1}^n I_i}{m}$$

Donde I_i es una función discreta que toma valor 1 si el modelo acertó al signo del cambio y toma valor cero si no acertó, con m igual al número de predicciones.

$$SRI = P * S + (1 - P) * (1 - S)$$

Donde

$$P = \frac{\text{signos positivos observados}}{\text{datos totales}} = \frac{\sum_{i=1}^n I_i(Y > 0)}{m} \quad \text{y}$$

$$S = \frac{\text{signos positivos proyectados}}{\text{datos totales}} = \frac{\sum_{i=1}^n I_i(X > 0)}{m}$$

Donde Y corresponde a los signos observados y X corresponde a los signos proyectados. Además, tenemos que las varianzas de SRI y SR se definen como

$$Var(SRI) = \frac{\{m(2S - 1)^2 P(1 - P) + m(2P - 1)^2 S(1 - S) + 4PS(1 - P)(1 - S)\}}{m^2} \quad \text{y}$$

$$Var(SR) = \frac{SRI(1 - SRI)}{m}$$

Una vez calculado el valor estadístico del test (DA), lo comparamos con un valor crítico de la tabla de distribución normal, dado que es ésta la distribución del test. En esta tesis utilizaremos un t crítico de 1,96, que arroja un 99% de confianza.

Para además confirmar que nuestros resultados sean consistentes al aplicarlos a otras series, estimamos el mismo modelo pero con submuestras de cien datos, de los

cuales la mitad se utilizó como periodo intramuestral y la otra mitad como periodo extramuestral. Dado que sólo utilizamos cien datos, pudimos realizar este cálculo con 59 submuestras, agregando un dato al final de la serie y eliminando el primer dato. En otras palabras, si la primera serie comenzaba en enero de 1994 y terminaba en abril de 2002, la segunda serie comenzaba en febrero de 1994 y terminaba en mayo de 2002, y así sucesivamente. Si bien una alternativa mejor para realizar los cálculos es emplear un método de *bootstrap* en bloques, dada la corta duración de nuestras series, se prefirió la metodología antes descrita. Los resultados obtenidos mediante la aplicación del modelo a las 59 submuestras, si bien no son tan consistentes como si hubiésemos realizado un *blockbootstrap*, de todas formas son válidos para comprobar la robustez de nuestras estimaciones.

4. Resultados

La RNA Ward anteriormente descrita fue aplicada efectivamente a las doce series de datos de viviendas, a las que se les aplicó el test de robustez previamente explicado.

La tabla 1 presenta los resultados de nuestra estimación con la red antes descrita. Podemos observar que de las doce series analizadas, en seis de las series nuestro modelo arroja capacidad de predicción, como demuestra el rechazo del valor calculado en el test de Acierto Direccional. En todas las series nuestros PPS son importantes, llegando a un PPS extramuestral de 71,43% junto a un PPS intramuestral de 60,53% en los precios de los departamentos del barrio El Golf.

En otras palabras, el modelo predijo correctamente el 71,43% de las veces que se vio enfrentado a los datos fuera de la muestra inicial. Para el caso de la serie de El Golf, los PPS no sólo son significativos y existe capacidad de predicción, sino que la rentabilidad del modelo supera a una estrategia *Buy & Hold*, alcanzando un 0,36% de rentabilidad frente a un -12,44% con la estrategia *B&H*.

Por otra parte, existen series con resultados muy poco concluyentes, como el caso de los departamentos en la comuna de Ñuñoa, donde se alcanza un PPS intramuestral de 61,84% y un PPS extramuestral de apenas 62,34%. Si bien por sí solo no es un mal resultado, el modelo entrega una rentabilidad menor a la de una estrategia de *Buy & Hold* y además el test de Pesaran y Timmermann no logra rechazar la independencia de las predicciones de los valores observados, es decir, no se puede confirmar la existencia de capacidad de predicción.

Para la mayoría de las demás series el modelo arroja resultados intermedios, en que los PPS si bien son buenos, o la rentabilidad del modelo no supera el *B&H*, o no se rechaza el test de Acierto Direccional. Solamente en tres de las series el modelo cumple con todos los estándares de una buena predicción: Los precios de los departamentos de Vitacura y El Golf y de las casas de Peñalolén pueden ser predichos con altos PPS, rentabilidades que superan nuestro *benchmark* y rechazo al test de Acierto Direccional.

Existen en total seis series en que se rechaza el test de P&T, y en siete de las series el modelo arroja mejores rentabilidades que el *B&H*. Por ello, podemos intuir que nuestro modelo entrega resultados más bien modestos, probando por cierto

nuestra hipótesis de existencia de capacidad de predicción en los precios del mercado inmobiliario, aún cuando los resultados sean heterogéneos entre distintas comunas.

Si realizamos la prueba que en la sección 3 iv) describimos para obtener resultados más robustos, llegamos a los resultados que muestra la tabla 2. En ella podemos apreciar que al aplicar la red a una serie de cien datos e ir cambiando un dato en cada una de las cincuenta y nueve series, llegamos a resultados bastante menos atractivos.

Las columnas III a VII muestran valores promedio de las 59 series; las columnas VIII y IX representan el porcentaje de veces que el test de Acierto Direccional fue rechazado y las veces que la rentabilidad del modelo superó al *Buy & Hold*. Si observamos con atención, las series que tienen mejores resultados no son necesariamente las series para las cuales el modelo original aplicado a la totalidad de los datos entregó el mejor resultado. Para las casas de Peñalolén, sólo en el 38,98% de las series el test de P&T fue rechazado y el modelo superó en rentabilidad al *B&H* tan sólo el 37,29% de las veces. Existen casos extremos como el de los departamentos en Las Condes, donde el test de Acierto Direccional no fue rechazado en ninguna ocasión, pero la rentabilidad del modelo superó al *B&H* en todas las series. Para nuestra serie de El Golf, los resultados arrojan capacidad de predicción en todas las ocasiones, pero el *B&H* supera al modelo el 86,44% de las veces.

En resumen, de acuerdo a este análisis, en sólo cuatro de las doce series tenemos capacidad predictiva y sólo en tres ocasiones nuestro modelo brinda mejor rentabilidad que la del *B&H*. Los PPS, no obstante, siguen siendo bastante altos.

Pese a que estos resultados no son muy alentadores, nos indican que nuestro modelo podría ser mejorado y obtener potencialmente mejores resultados. Además, cabe señalar que como estamos aplicando la red a un conjunto de datos mucho menor, (un 37% menor que la serie total) nuestra RNA Ward no tiene muchos datos para ajustarse y por lo tanto tampoco podría obtener los mismos resultados que si la entrenamos con toda la serie intramuestral. Por desgracia, mientras no dispongamos de una serie de datos mayor, difícilmente podremos implementar tests de robustez que brinden resultados confiables.

TABLA 1: RESULTADOS RED NEURONAL

PPS INTRAMUESTRAL	CASAS					DEPARTAMENTOS						
	La Florida - Puente Alto	Peñalolén	Maipú - Cerrillos	Quilicura	Las Condes	Providencia	Las Condes	El Golf	Vitacura	Ñuñoa	Centro	San Miguel
PPS EXTRAMUESTRAL	61,84%	65,79%	65,79%	60,53%	60,53%	61,84%	60,53%	60,53%	60,53%	61,84%	61,84%	61,84%
DESVIACION ESTANDAR	72,73%	67,53%	68,83%	63,64%	64,94%	70,13%	63,64%	71,43%	70,13%	62,34%	72,73%	63,64%
RENTABILIDAD DEL MODELO	12,88%	15,91%	19,54%	11,13%	10,69%	16,93%	16,54%	17,88%	13,20%	13,22%	8,40%	15,60%
RENTABILIDAD BUY & HOLD	-1,78%	2,28%	-3,04%	0,19%	-0,36%	0,14%	-0,67%	0,36%	-2,21%	-0,09%	0,01%	2,98%
TEST ACIERTO DIRECCIONAL	13,56%	-8,34%	7,90%	3,10%	-13,14%	-6,84%	-13,05%	-12,44%	-20,88%	0,45%	12,90%	0,97%
	Se Rechaza	Se Rechaza	Se Rechaza	No Se Rechaza	No Se Rechaza	No Se Rechaza	No Se Rechaza	Se Rechaza	Se Rechaza	No Se Rechaza	Se Rechaza	No Se Rechaza

Las primeras dos filas presentan los PPS intra y extramuestrales, respectivamente. La tercera fila presenta la desviación estándar de los PPS extramuestrales. La cuarta y quinta filas presentan las rentabilidades obtenidas al seguir el modelo u optar por seguir una metodología de comprar y mantener el activo durante todo el período, para luego venderlo al final. La última fila presenta los resultados del test de Pesaran y Timmermann: cuando en una serie se rechaza el test, implica que existe capacidad predictiva.

TABLA 2: RESULTADOS TEST DE ROBUSTEZ

I TIPO DE VIVIENDA	II COMUNA O ÁREA	III PPS INTRAMUESTRAL	IV PPS EXTRAMUESTRAL	V DESVIACIÓN ESTANDAR	VI RENTABILIDAD DEL MODELO	VII BUY & HOLD	VIII TEST DA	IX RENT. MODELO > RENT. B&H
	Florida-Puente	62,92%	77,45%	12,99%	0,56%	20,77%	94,92%	1,69%
	Peñalolén	62,39%	68,66%	13,66%	0,16%	2,40%	38,98%	37,29%
CASAS	Maipú- Cerrillos	62,75%	69,49%	12,67%	0,05%	4,63%	30,51%	20,34%
	Quilicura	62,50%	68,77%	12,45%	-0,03%	0,61%	3,39%	49,15%
	Las Condes	62,54%	69,08%	13,63%	-0,11%	-6,46%	47,46%	94,92%
	Providencia	62,85%	68,52%	12,64%	-0,10%	-6,15%	11,86%	94,92%
	Las Condes	62,57%	68,77%	12,67%	-0,35%	-10,72%	0,00%	100,0%
DEPARTA -	El Golf	63,52%	75,51%	12,33%	0,25%	5,93%	100,0%	13,56%
MENTOS	Vitacura	61,76%	71,39%	12,28%	-0,45%	-14,96%	91,53%	100,0%
	Ñuñoa	62,78%	66,79%	13,18%	0,06%	-0,59%	11,86%	50,85%
	Centro	62,29%	70,01%	11,29%	0,14%	3,46%	81,36%	25,42%
	San Miguel	62,50%	68,35%	12,04%	-0,08%	-6,19%	20,34%	79,66%

Todos los resultados presentados en la tabla son promedios de las 59 submuestras generadas a partir de la muestra total. La columna VIII presenta cuántas veces fue rechazado el test de Acierto Direccional, es decir, de todas las submuestras, en cuántas se halló capacidad predictiva. La columna IX presenta el porcentaje de veces que la rentabilidad del modelo fue mayor que la de un Buy & Hold, entre todas las submuestras.

5. Conclusiones

A continuación se resume el propósito de este seminario, su metodología y sus principales resultados, para terminar con algunas recomendaciones para futuras investigaciones ligadas a este tópico.

i. Conclusiones del Modelo

El objetivo de esta tesis ha sido determinar la existencia de capacidad predictiva del signo de los precios del mercado inmobiliario chileno. Para ello se empleó un modelo de red neuronal artificial Ward.

Los resultados arrojan capacidad predictiva importante en seis de las doce series de datos analizadas, y en siete de las series el modelo superó en rentabilidad a nuestro *benchmark*. Sólo en tres series obtuvimos tanto el rechazo del test de Acierto Direccional como una mejor rentabilidad que el *B&H*. En las demás series obtuvimos resultados mixtos, en que o el modelo era rentable y no se rechazaba el test de P&T, o el test se rechazaba pero la rentabilidad era menor a la del *benchmark*.

Al realizar un test de robustez, en que calculamos el modelo para 59 submuestras de 100 datos y obtuvimos el promedio de los resultados, nos encontramos con resultados menos atractivos. Sólo cuatro series rechazaron el test de Acierto Direccional y sólo seis superaron la rentabilidad del *B&H*. En conjunto, ninguna serie superó el *B&H* y a la vez rechazó el test de P&T. Pese a ello, sabemos que los resultados de este test estarán negativamente sesgados, dado que la red tenía un 37% menos de datos para entrenarse. Dado que nuestra serie de por sí es extremadamente corta (un total de 159 observaciones) buena parte de estos magros resultados en este test se podrían explicar por la falta de datos.

De todo el análisis realizado, podemos confirmar que existe capacidad predictiva en las series de precios promedio de inmuebles en la capital de Chile, pero que estos resultados no son homogéneos a través de los distintos sectores y tipos de vivienda de Santiago. Nuestro modelo ha probado ser una herramienta útil a la hora de detectar capacidad predictiva, pero aún está lejos de entregar resultados que pudieran

satisfacer los requerimientos mínimos de un inversionista que decidiera invertir en bienes inmuebles.

Esto significa que para mejores predicciones y resultados se debería probar con una serie de modelos diferentes –no sólo redes neuronales artificiales– con el objeto de determinar cuál es el mejor predictor del cambio en los precios para este tipo de datos.

Otra conclusión importante de nuestro análisis es la escasa información disponible sobre el mercado inmobiliario chileno. No existen bases de datos completas, y las que existen – como la de la CChC – no son constantes en el tiempo y están truncadas. Organismos públicos como el INE y el Ministerio de Vivienda y Urbanismo, no tienen bases de datos que publiquen periódicamente. Solamente se publican los agregados de construcción de vivienda para todo el país, si bien con frecuencia mensual, pero sin un desglose por comunas o por características de las viviendas¹⁷.

El sector de la construcción, aparte de ser un componente importante del PIB, es un demandante importante de mano de obra. Dado que los bienes que genera son de larga duración y por lo mismo, caros, este sector es sumamente sensible a los ciclos económicos (inflación, crecimiento, tasa de interés, expectativas económicas, son todas variables que inciden inmediatamente en el sector). Baste recordar que después de la crisis asiática, mientras el PIB se contrajo en un 0,8%, la construcción se redujo en un 9,9%.

Disponer de más y mejor información sobre este sector de la economía es vital, no sólo desde el punto de vista financiero de un inversionista inmobiliario, sino también del gobierno, toda vez que información actualizada sobre el comportamiento de este sector puede ser un indicativo de cómo el resto de la economía se podría comportar en un futuro cercano. Los municipios también se verían beneficiados de existir mejores bases de datos, pudiendo analizar directamente cómo ha afectado a los precios un cambio en el plano regulador de la comuna, o la remodelación de un sector de ella.

Finalmente, otra conclusión importante tiene relación con el comportamiento heterogéneo de las comunas modeladas. El modelo no puede explicar por qué es exitoso al ser aplicado a comunas como Vitacura, Peñalolén y el barrio El Golf, mientras que en Quilicura, San Miguel y Ñuñoa no se logra capacidad predictiva ni se logra superar la rentabilidad del Buy & Hold. Suponemos que la explicación podría ser alternativamente a la ya descrita mala calidad de los datos, la sensibilidad distinta de

¹⁷ INE, "Compendio Estadístico 2006", 2006.

las comunas a los cambios en el crecimiento del país y las variaciones de la tasa de interés. Por ejemplo, los precios de los inmuebles en una comuna podrían deberse a otras variables tales como las expectativas económicas o el nivel de desempleo, mientras que otras comunas sí podrían estar relacionadas con las tasas de interés y el crecimiento mensual de la economía.

Una variable que merece especial atención en el mercado inmobiliario, es el cambio en el plan regulatorio de cada comuna. Si un municipio decide permitir la construcción de vivienda en altura o permitir edificios de oficinas o centros comerciales en un sector, influye directamente en los precios de los terrenos y –por ende- en el precio de las viviendas allí construidas, dada la nueva demanda por terrenos en ese sector, y por la mayor (o menor) valorización de vivir en un barrio con nuevas características. La construcción de grandes obras públicas –como una nueva línea del metro o una autopista urbana- también podrían explicar algunas variaciones que no logramos captar en nuestro modelo.

Este y otros puntos que podrían mejorar las estimaciones se discuten brevemente en el apartado siguiente.

ii. Futuras Áreas de Investigación

Como mencionábamos en la sección anterior, la falta de información primaria es una limitante importante para desarrollar investigación en esta área. Por ello sería en extremo beneficioso si organismos públicos o privados pudieran recolectar información de mayor periodicidad y con mayor detalle, y además permitir que esta información esté disponible para la población general. La información no sólo debiera limitarse a las comunas del Gran Santiago, debería incluir a todas las comunas del país.

En relación al mercado inmobiliario, tampoco existen estudios que analicen la evolución de la calidad de la oferta inmobiliaria a través del tiempo. Los precios, si bien pueden reflejar cambios en calidad de las viviendas, también están influidos por los cambios en el valor del suelo o por la mayor disposición a pagar por ese sector, dado un cambio en las preferencias de los demandantes.

Otro aspecto que podría investigarse es el por qué de las diferencias en precios de un sector a otro dentro de la capital, en función de variables como acceso a movilización, tranquilidad y seguridad del barrio, cercanía con colegios, supermercados

y fuentes de trabajo, etc. Este tipo de análisis se ha realizado en numerosas investigaciones en otros países. En Chile, probablemente, no se ha podido realizar simplemente por la falta de información. Nuevamente, cabe mencionar como potencial variable explicativa la construcción de grandes obras de infraestructura (metro o carreteras) y de centros comerciales, así como cambios en el plan regulador de una comuna.

Existe un sinnúmero de aristas que se podrían abordar para mejorar las estimaciones del modelo aquí desarrollado. No queda claro si las RNA Ward son las mejores redes para series de precios de inmuebles, que presentan características diferentes a las de los instrumentos financieros tradicionales. Tampoco se realizó el modelo con una ventana recursiva o con ventanas *rolling* de mayor o menor tamaño. Queda por investigar si acaso existen otras variables que expliquen mejor el comportamiento de la serie, o si el número de rezagos de las variables independientes utilizadas es el óptimo.

Por otro lado, el presente trabajo ha ignorado una serie de problemas que podrían afectar la estimación de nuestro modelo. En primer lugar, no se pudo acceder a una base de datos más completa, quedando pendiente la realización de este estudio en series más completas de información. En segundo lugar, se hizo caso omiso del problema de datos truncados que afecta a la serie. Una mayor investigación implicaría realizar estimaciones en base a los modelos de Heckman en dos etapas para datos con sesgo de selección y datos truncados. Tampoco se realizaron tests para determinar la existencia de heteroscedasticidad o autocorrelación, que nuevamente podrían influir en el resultado de nuestras estimaciones.

Esperamos que estos aspectos motiven una mayor investigación en el área de la predicción de precios de inmuebles.

Bibliografía

Campbell, J.; Lo, A.; MacKinlay, A. *"The econometrics of financial markets"*. Princeton University Press. 1997.

Fama, Eugene F. *"Efficient capital markets: a review of theory and empirical work."* Journal of finance. Mayo 1970.

Fama, Eugene F. *"Efficient capital markets: II"*. Journal of finance. December 1991.

Ferson, W y Harvey, C. *The variation of economic risk premiums"*. Journal of Political Economy 99, 1991.

Gavridis, M. *"Modelling with high frequency data: a growing interest for financial economists and fund managers"*. Nonlinear Modelling of High Frequency Financial Time Series. Dunis, C. Zhou, B. Editores. 1998.

Instituto Nacional de Estadísticas *"Compendio Estadístico 2006"*, INE, 2006.

Kuan, C.-M. *"Artificial Neuronal Networks"*, Working Paper, Institute of Economics, Academia Sinica, Taipei, 1998.

Leung, M. T.; Daouk, H y Cheng, A. *"Forecasting stock indices: a comparison of classification and level estimation models"*. International Journal of Forecasting 16. 2000.

Lo, A. y MacKinlay, A. C. *"Stock market prices do not follow random walk: Evidence from simple specification test."* Review of Financial Studies. 1988.

Markowitz, H.M. *"Portfolio selection"*. Journal of finance Vol. 7. 1952.

Markowitz, H.M. *"Portfolio selection: efficient diversification of investments"*. John Wiley and Sons Inc. 1959.

Martín del Brío, B. y Sanz Molina, A. *"Redes neuronales y sistemas borrosos"*. Editorial RA-MA, Madrid, 1997.

Parisi, Antonino; Parisi, Franco y Guerrero, José Luis. *"Redes neuronales en la predicción de Índices bursátiles internacionales: Un análisis de la estabilidad de los pesos"*. El trimestre económico. México, 2003.

Parisi, Antonino, *"Modelos de redes neuronales Rolling: tamaño muestral óptimo"*, Facultad de Ciencias Económicas y Administrativas, Universidad de Chile, 2003.

Pesaran, M. H. y Timmermann, A. *"A simple non parametric test of predictive performance"*. Journal of Business and Economic Statistics, 1992.

Reyes, Daniel y Tapia, Victor. *"Evaluación de los distintos modelos de redes neuronales en la predicción de valores financieros"*. Facultad de Ciencias Económicas y Administrativas, Universidad de Chile. Chile, 2000.

Páginas Web:

Banco Central de Chile: www.bcentral.cl

Cámara Chilena de la Construcción: www.cchc.cl

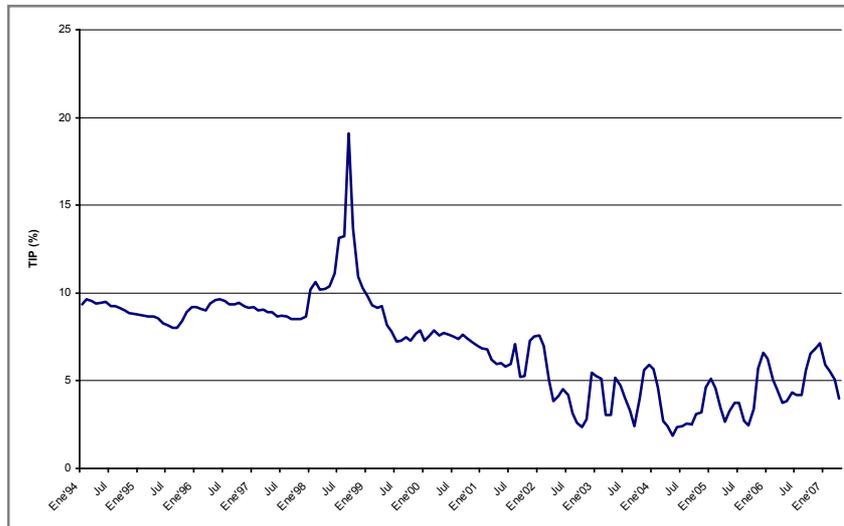
Google Scholar: scholar.google.com

Instituto Nacional de Estadísticas: www.ine.cl

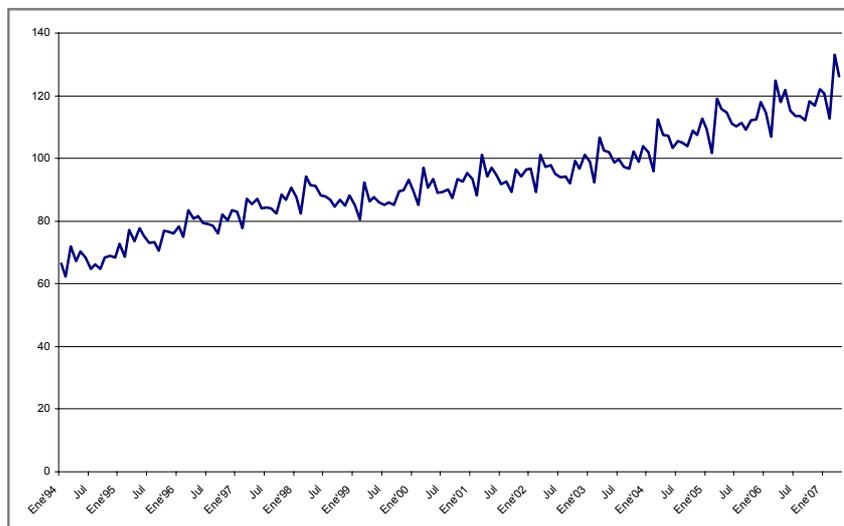
ParisiNet: www.parisinet.com

Anexos

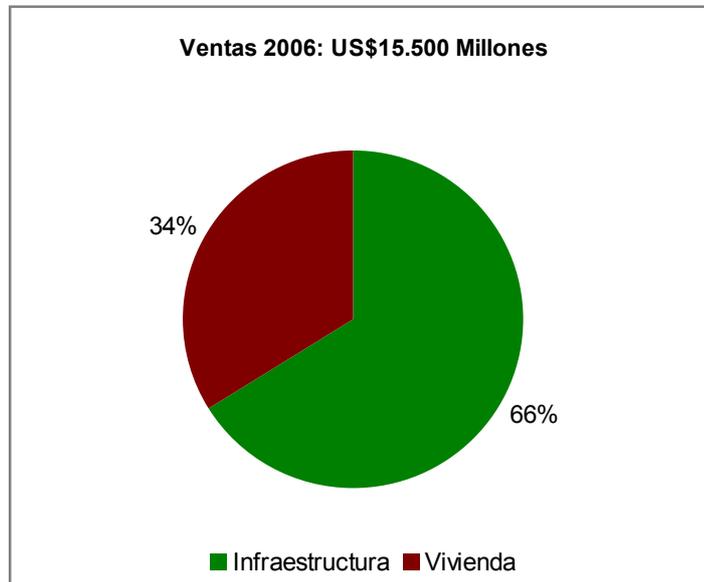
i. Evolución Tasa de Interés Promedio (colocaciones 90-365 días) en UF



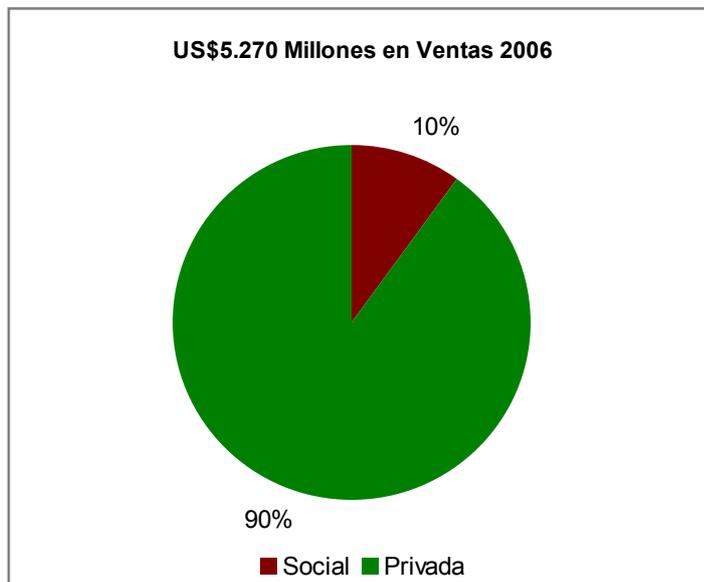
ii. Evolución IMACEC, base 100 = Enero 2003 (serie estacional)



iii. Desglose del Mercado de la Construcción¹⁸



iv. Descomposición Construcción de Vivienda



¹⁸ Fuente: Cámara Chilena de la Construcción, para los apartados C al E.

v. Descomposición Construcción de Infraestructura

