


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA  
DEPARTAMENTO DE INDUSTRIAS  
VALPARAÍSO - CHILE



PRONÓSTICO PARA LOS RETORNOS ANORMALES DE LAS ACCIONES CHILENAS  
EN TORNO AL EX DIVIDEND DAY MEDIANTE REDES NEURONALES ARTIFICIALES

DANIELA ANGÉLICA PONCE DÍAZ

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

PROFESOR GUÍA : DR. WERNER KRISTJANPOLLER  
PROFESOR CORREFERENTE :MG. KEVIN MICHELL

SEPTIEMBRE 2019

# Agradecimientos

Este trabajo de título, es dedicado a mi hermosa familia, mis padres y hermanos quienes me han dado su apoyo incondicional a lo largo de mi carrera universitaria y en especial en este periodo de preparación de este trabajo de título. Mencionar principalmente a mis hermanas Jessica y Mariela, quienes son mi ejemplo a seguir y mi mayor inspiración y a mi amada madre Angélica, quien sin duda, ha sido el apoyo fundamental durante toda mi vida y mi carrera universitaria. Gracias totales a todos, los amo mucho.

Además agradecer a mi pololo Felipe, lo mejor que me llevo de la universidad. Gracias por el apoyo entregado en todo este proceso, por tu paciencia y entrega en todo lo que he necesitado. Sin duda, la vida nos eligió para unir lo mejor de nosotros en esta linda relación. Muchas gracias, te amo mucho.

Gracias a mis amigos, que son muy importantes en todo el periodo universitario. Gracias a cada uno de ustedes por los trabajos en grupo, los estudios hasta tarde, los carretes y risas infinitas. Sin duda, la universidad me dejo los mejores amigos que podría pedir. Gracias especiales a Andrea, que fue mi fiel compañera durante toda la carrera, mi gran apoyo y mi mejor amiga.

Finalmente agradezco al profesor Werner, quien como jefe de carrera me ayudó mucho en mis años de universidad, especialmente en los últimos años con mi interés en el área financiera. Gracias por aceptar ser mi profesor guía en este trabajo y ayudarme en todo, especialmente cuando no pude estar presencialmente en la universidad. Gracias también al profesor Kevin, por aceptar ser mi profesor cooreferente en este trabajo.

# Resumen Ejecutivo

El inversionista tiene varios factores que influyen en la elección del instrumento financiero en el cual quiera invertir. Al hablar de la inversión en acciones, se debe tener en consideración que existen múltiples variables que hacen incierto el resultado y que no existe un modelo que pueda predecir en su totalidad cual es el mejor momento de invertir, ni en qué acciones, como tampoco en que proporción. Esta es la tolerancia al riesgo que el inversor está dispuesto a aceptar.

Sin embargo existen algunas variables que pueden direccionar la elección del inversor. En este trabajo se presentaran las herramientas y variables que ayudan en la elección del momento temporal en el cual el inversor obtendrá mayor rentabilidad al vender sus acciones (también se podría extrapolar el caso de compra).

Este momento temporal se divide por la fecha límite de las acciones, la cual determina si el accionista tiene derecho o no al dividendo pagado por dicha acción. Si el accionista vende la acción antes de la fecha límite, tiene derecho al pago del dividendo, y tiene que considerar además la tasa impositiva pagada por esta ganancia. Si el inversionista vende su acción después de la fecha límite, no tiene derecho al pago del dividendo, ahorrándose este impuesto y solo declarando la ganancia de capital obtenida en esta transacción, las cuales no son gravadas si no son “frecuentes”.

Para esto, se seleccionan las acciones más transadas en la bolsa, insertas en el antiguo índice de mercado IPSA. Tomando los dividendos pagados entre los años 2007 y 2017, se obtiene la caída de precio entre estas fechas, y el dividendo pagado por la acción. En un mercado perfecto esta caída de precio debe ser igual al valor del dividendo, sin embargo en este mundo menos perfecto, esto no sucede. Con este ratio, se puede obtener si al inversionista le conviene invertir antes o después de la fecha ex dividend (sin dividendo). Si la caída de precio es mayor al dividendo, el inversionista tendería a vender sus acciones antes del día ex dividend, ya que su rentabilidad sería mayor.

Este trabajo, ayuda a la decisión del inversor realizando dos modelos, con el primero se

obtienen las rentabilidades antes y después del día ex dividend, en donde se concluye si es mejor la venta antes o después de esta fecha. Esto se apoya con el segundo modelo, en donde se trabajan los ratios de caída de precio sobre dividendo, con y sin ajuste del mercado. Estos son 3 ratios, UR, AMR y AR, los cuales según el modelo de clientela tributaria, muestran si es mejor vender antes o después del día ex dividend las acciones para el mercado chileno.

Ambos modelos se realizan con redes neuronales artificiales, con diferentes configuraciones de entrenamiento y configuraciones de capas y neuronas, para finalmente concluir con un test de medias, la mejor opción de pronóstico. A modo de comparación también se realiza un modelo econométrico ARIMA, en donde se elige el mejor ARIMA, en base al estadístico Akaike. Finalmente se comparan para obtener que modelo y con que herramienta, ajusta más a la realidad.

Los resultados obtenidos por los mejores modelos encontrados, muestran una correcta relación con la realidad, en donde se señala que al inversor le conviene vender antes de la fecha ex dividend sus acciones, debido a que se obtiene mayor rentabilidad antes que después de dicha fecha. Apoyando este resultado, se presenta que los ratios caída de precio sobre dividendo presentan resultados mayores a uno, lo que indica que la tasa impositiva de la ganancia de capital es mayor que la tasa impositiva a los dividendos.

# Índice de Contenidos

<b>Capítulo</b>	<b>Agradecimientos</b>	<b>I</b>
<b>Capítulo</b>	<b>Resumen Ejecutivo</b>	<b>II</b>
<b>Capítulo 1</b>	<b>Problema de Investigación</b>	<b>1</b>
<b>Capítulo 2</b>	<b>Objetivos</b>	<b>3</b>
	2.1 Objetivo General . . . . .	3
	2.2 Objetivos Específicos . . . . .	3
<b>Capítulo 3</b>	<b>Marco Teórico</b>	<b>4</b>
	3.1 Mercado Financiero . . . . .	4
	3.1.1 Acciones . . . . .	5
	3.1.1.1 Inversión . . . . .	5
	3.1.2 Políticas de Dividendo . . . . .	6
	3.1.2.1 Dividendo . . . . .	6
	3.1.2.2 Ganancia de Capital . . . . .	6
	3.1.3 Fechas de interés . . . . .	7
	3.1.4 Índices accionarios . . . . .	7
	3.1.4.1 S&P/CLX IPSA . . . . .	8
	3.1.4.2 S&P/CLX IGPA . . . . .	8
	3.2 Efecto ex-dividend day . . . . .	10
	3.2.1 Causas . . . . .	10
	3.2.2 Indicadores . . . . .	12
	3.3 Inteligencia artificial . . . . .	15
	3.3.1 Redes neuronales artificiales (RNA) . . . . .	16
	3.3.1.1 Neurobiología . . . . .	16
	3.3.1.2 Modelos Neuronales . . . . .	18

3.3.1.3	Función de activación	20
3.3.1.4	Neurona	22
3.3.1.5	Capas	23
3.3.1.6	Estructuras de conexión	23
3.3.1.7	Fases	24
3.3.1.8	Aprendizaje	25
3.3.1.9	Aprendizaje supervisado	25
3.3.1.10	Aprendizaje no supervisado	26
3.3.2	Tipos de redes neuronales	26
3.3.2.1	Red monocapa	26
3.3.2.2	Red multicapa	26
3.4	Modelos econométricos	27
3.4.1	Series de tiempo	27
3.4.1.1	Concepto de estacionalidad	27
3.4.1.2	Proceso autorregresivo (AR)	28
3.4.1.3	Proceso de medias móviles (MA)	28
3.4.1.4	Proceso autorregresivo y de promedios móviles (ARMA)	29
3.4.1.5	Proceso autorregresivo integrado de promedios móviles (ARIMA)	29
3.5	Prueba estadística	30
3.5.1	t-student	30

**Capítulo 4 Metodología** **32**

4.1	Datos	32
4.2	Efecto exdividend en Chile	32
4.3	Pronóstico para decisión del inversor	35
4.3.1	Redes Neuronales Artificiales: Aplicación	36
4.3.1.1	Entradas	36
4.3.1.2	Salidas	37
4.3.1.3	Estructura	38
4.3.1.4	Modelos	39
4.3.2	Modelo Econométrico: ARIMA	41
4.4	Mejor modelo: Comparación estadística	42

<b>Capítulo 5 Resultados</b>	<b>44</b>
5.1 Efecto ex dividend en las acciones Chilenas . . . . .	44
5.2 Modelos y configuraciones . . . . .	48
5.2.1 Modelo para decisión de compra/venta según rentabilidad esperada	49
5.2.2 Modelo para decisión de compra/venta según principales indicado- res de inversión . . . . .	58
<b>Capítulo 6 Conclusiones y recomendaciones</b>	<b>71</b>
<b>Bibliografía</b>	<b>76</b>



# Índice de Tablas

3.1	Comparación cerebro humano y computador . . . . .	17
4.1	Resumen modelos. Fuente: Elaboración propia . . . . .	40
5.1	Extracto de data de estadísticos. Fuente: Elaboración propia . . . . .	45
5.2	Rentabilidades, entrenamiento 85 %. Fuente: Elaboración propia . . . . .	49
5.3	Media rentabilidades antes. Fuente: Elaboración propia . . . . .	50
5.4	Media rentabilidades después. Fuente: Elaboración propia . . . . .	50
5.5	Configuraciones que aceptan H0. Fuente: Elaboración propia . . . . .	50
5.6	Rentabilidades, entrenamiento 80 %. Fuente: Elaboración propia . . . . .	51
5.7	Media rentabilidades antes. Fuente: Elaboración propia . . . . .	51
5.8	Media rentabilidades después. Fuente: Elaboración propia . . . . .	51
5.9	Configuraciones que aceptan H0. Fuente: Elaboración propia . . . . .	52
5.10	Rentabilidades, entrenamiento 90 %. Fuente: Elaboración propia . . . . .	52
5.11	Media rentabilidades antes. Fuente: Elaboración propia . . . . .	52
5.12	Media rentabilidades después. Fuente: Elaboración propia . . . . .	53
5.13	Configuraciones que aceptan H0. Fuente: Elaboración propia . . . . .	53
5.14	Tabla comparación. Fuente: Elaboración propia . . . . .	53
5.15	Rentabilidades, entrenamiento 80 %. Fuente: Elaboración propia . . . . .	54
5.16	Media rentabilidades antes. Fuente: Elaboración propia . . . . .	54
5.17	Media rentabilidades después. Fuente: Elaboración propia . . . . .	55
5.18	Configuraciones que aceptan H0. Fuente: Elaboración propia . . . . .	55
5.19	Rentabilidades, entrenamiento 90 %. Fuente: Elaboración propia . . . . .	55
5.20	Media rentabilidades antes. Fuente: Elaboración propia . . . . .	56
5.21	Media rentabilidades después. Fuente: Elaboración propia . . . . .	56
5.22	Configuraciones que aceptan H0. Fuente: Elaboración propia . . . . .	56
5.23	Tabla comparación. Fuente: Elaboración propia . . . . .	56
5.24	Estadísticos, entrenamiento 85 %. Fuente: Elaboración propia . . . . .	59

5.25 Media UR. Fuente: Elaboración propia . . . . .	59
5.26 Media AMR. Fuente: Elaboración propia . . . . .	59
5.27 Media AR. Fuente: Elaboración propia . . . . .	59
5.28 Configuraciones que aceptan H0. Fuente: Elaboración propia . . . . .	59
5.29 Media de cada estadístico según mejor opción . . . . .	60
5.30 Estadísticos, entrenamiento 85 %. Fuente: Elaboración propia . . . . .	61
5.31 Media UR. Fuente: Elaboración propia . . . . .	61
5.32 Media AMR. Fuente: Elaboración propia . . . . .	61
5.33 Configuraciones que aceptan H0. Fuente: Elaboración propia . . . . .	61
5.34 Estadísticos, entrenamiento 90 %. Fuente: Elaboración propia . . . . .	62
5.35 Media UR. Fuente: Elaboración propia . . . . .	62
5.36 Media AMR. Fuente: Elaboración propia . . . . .	62
5.37 Configuraciones que aceptan H0. Fuente: Elaboración propia . . . . .	62
5.38 Tabla comparación. Fuente: Elaboración propia . . . . .	63
5.39 Medias de cada estadístico. Fuente: Elaboración propia . . . . .	63
5.40 Estadísticos, entrenamiento 80 %. Fuente: Elaboración propia . . . . .	64
5.41 Media UR. Fuente: Elaboración propia . . . . .	64
5.42 Media AMR. Fuente: Elaboración propia . . . . .	64
5.43 Configuraciones que aceptan H0. Fuente: Elaboración propia . . . . .	64
5.44 Estadísticos, entrenamiento 80 %. Fuente: Elaboración propia . . . . .	65
5.45 Media UR. Fuente: Elaboración propia . . . . .	65
5.46 Media AMR. Fuente: Elaboración propia . . . . .	65
5.47 Configuraciones que aceptan H0. Fuente: Elaboración propia . . . . .	66
5.48 Tabla comparación. Fuente: Elaboración propia . . . . .	66
5.49 Medias de cada estadístico. Fuente: Elaboración propia . . . . .	66
5.50 Resumen mejores modelos por caso. Fuente: Elaboración propia . . . . .	68
5.51 Cantidad de configuraciones aceptadas, $\alpha$ 5 %. Fuente: Elaboración propia . . . . .	68
5.52 Cantidad de configuraciones aceptadas, $\alpha$ 10 %. Fuente: Elaboración propia . . . . .	69
5.53 Resumen diferencias entre las medias de las series. Fuente: Elaboración propia . . . . .	69
5.54 Medias-Medianas de las series. Fuente: Elaboración propia . . . . .	69
5.55 Medias-Medianas de las series. Fuente: Elaboración propia . . . . .	70

# Índice de Figuras

3.1	Fechas de interés (Fuente: Elaboración Propia) . . . . .	7
3.2	Relación entre la rentabilidad por ganancia de capital y el dividendo pagado . .	13
3.3	Representación Neurona. Extraído de: <a href="http://www.down21.org">www.down21.org</a> . . . . .	17
3.4	Representación sinapsis. Extraído de: <a href="https://www.psicoactiva.com/blog/la-sinapsis-neuronal-tipos-sinapsis/">https://www.psicoactiva.com/blog/la-sinapsis-neuronal-tipos-sinapsis/</a> . . . . .	18
3.5	Representación sinapsis. Extraído de: Redes Neuronales artificiales (Izaurieta) .	19
3.6	Activación neurona. Extraído de: <a href="https://ernestocrespo13.files.wordpress.com">https://ernestocrespo13.files.wordpress.com</a> .	19
3.7	Función de activación lineal. Extraído de: <a href="https://www.researchgate.net">https://www.researchgate.net</a> . . . . .	20
3.8	Función de activación sigmoidea. Extraído de: <a href="https://developers.google.com/machine-learning/crash-course/introduction-to-neural-networks/anatomy?hl=es-419">https://developers.google.com/machine-learning/crash-course/introduction-to-neural-networks/anatomy?hl=es-419</a> . . . . .	21
3.9	Función de activación tangente hiperbólica. Extraído de: <a href="https://www.researchgate.net/figure/Figura-17-Funcion-de-activacion-de-tangente-hiperbolica_fig20_328600321">https://www.researchgate.net/figure/Figura-17-Funcion-de-activacion-de-tangente-hiperbolica_fig20_328600321</a> . . . . .	21
3.10	Diagrama red neuronal, capas. Extraído de: Redes Neuronales: Conceptos Básicos y Aplicaciones (Damian Jorge Matich, 2001) . . . . .	23
3.11	Diagrama estructuras de conexión. Extraído de: <a href="http://inteligenciaartificialudb.blogspot.com/">http://inteligenciaartificialudb.blogspot.com/</a> 24	
5.1	Dividendo v/s caída de precio.Fuente: Elaboración propia . . . . .	47
5.2	Casos para modelo 1 y 2.Fuente: Elaboración propia . . . . .	49
5.3	Mejores modelos rentabilidad antes. Fuente: Elaboración propia . . . . .	57
5.4	Mejores modelos rentabilidad después. Fuente: Elaboración propia . . . . .	58
5.5	Mejores modelos UR. Fuente: Elaboración propia . . . . .	67
5.6	Mejores modelos AMR. Fuente: Elaboración propia . . . . .	67

# 1 Problema de Investigación

El riesgo en las inversiones corresponde al grado de incertidumbre que se tiene al esperar el rendimiento que otorgara dicha inversión, es la decisiva para el inversor a la hora de realizar cualquier movimiento. ¿Existirán variables que determinen el momento adecuado para comprar o vender las acciones que se desean transar? ¿Se podrá predecir dicho rendimiento?.

En la actualidad el comportamiento de los inversores es un tema de estudio interesante, que muestra decisiones que no se desprenden completamente de la racionalidad de los postulados de la economía clásica. Además, el conocer mejor los mercados accionarios permite a los agentes tomar mejores decisiones (Kristjanpoller, 2009).

Un dividendo es una remuneración por parte de una empresa a sus accionistas. Puede ser en forma de dinero o en acciones. Para los accionistas el dividendo es parte de la rentabilidad que obtienen de su inversión. La política de pago de dividendos debe ser analizada considerando que las sociedades anónimas chilenas tienen la obligación de pagar al menos el 30 % de sus utilidades como dividendo obligatorio (Gutiérrez et al., 2012), lo que según Nash and Fuenzalida (2004), hace que sea extremadamente importante medir el impacto de la distribución de dividendos en los retornos.

En un mercado de capital perfecto, el precio de la acción en el día ex dividendo debiese caer exactamente por el monto del dividendo pagado en cada acción, lo que haría que fuera indiferente el momento en el cual se decida comprar o vender la acción (despreciando los impuestos). Sin embargo, los trabajos empíricos sobre este tema generalmente encuentran que, en promedio, los precios de las acciones en nuestro mundo menos perfecto caen por debajo del monto del dividendo en la fecha ex dividendo (Castillo and Jakob, 2006). Si bien este fenómeno no cuenta con una explicación determinada, existen algunos estudios y supuestos al respecto, como la estrecha relación entre el comportamiento de las acciones de una corporación en el día ex dividendo y las tasas de impuestos de sus accionistas. Un accionista que vende acciones antes de que una acción salga ex dividendo pierde el derecho al dividendo ya declarado. Si vende las acciones en el día ex

dividendo, conserva el dividendo, pero debería esperar venderlo a un precio inferior (debido a esta retención de dividendos, cae el precio). En un mercado racional la caída en el precio en el día ex dividendo debe reflejar el valor de los dividendos de ganancias de capital a los accionistas.

La primera causa de este efecto señala que los dividendos y ganancias de capital están sujetos a impuestos a tasas diferentes, la tasa de impuesto relativo en estos dos tipos de ingresos afecta a la decisión (Elton and Gruber, 1970). Los resultados del estudio realizado por Muñoz and Rodriguez (2017) indican que “la reducción del impuesto sobre los dividendos tiene un efecto en el índice de caída de precios”. Este resultado es consistente con la hipótesis del efecto clientela.

La hipótesis del efecto clientela sostiene que los inversionistas en firmas de bajo rendimiento de dividendos que tengan una relativa aversión a los dividendos verán un incremento en dividendos como una mala noticia, mientras que los que invierten en firmas de alto rendimiento que tengan preferencia por los dividendos reaccionarán positivamente ante un incremento inesperado en dividendos (Maquieira and Osorio, 2000), esto es que los inversionistas serán atraídos por firmas que representen sus preferencias en relación al nivel de pago y estabilidad de los dividendos.

Debido a que el inversor siempre busca sus mejores opciones según la rentabilidad que espera y el riesgo al cual se expone, es que busca predecir el comportamiento de la acción para la toma de decisión.

¿Existirá algún modelo que pueda predecir el momento en el cual el inversor deba vender/comprar sus acciones según los efectos particulares de cada país, como los experimentados en el día ex dividend en Chile?.

## 2 Objetivos

### 2.1. Objetivo General

Diseñar un modelo con diferentes herramientas para la predicción del mejor momento de compra/venta de las acciones en el mercado chileno, mediante estudios en las fechas límites de la acción para que el inversionista pueda contar con mayor información y menor incertidumbre en sus inversiones.

### 2.2. Objetivos Específicos

- Verificar la baja en el precio de la acción en el día ex dividendo mediante el modelo de clientela tributaria para comprobar si en Chile existen retornos anormales en dicha fecha.
- Identificar los comportamientos repetitivos dentro del periodo de estudio con herramientas como Excel o Matlab, para encontrar correlaciones que ayuden a la formación del modelo econométrico.
- Formular diferentes estadísticos que involucren la caída de precio y el monto del dividendo para ayudar a la decisión del inversor.
- Brindar una herramienta práctica para los inversionistas en base a un modelo de predicción, para que de esta forma puedan tomar mejores decisiones.
- Investigar sobre los posibles factores que tengan relación a la baja del precio de la acción en menor proporción que el dividendo de la misma, mediante estudios anteriores, con lo que se obtendrá información para posibles variables de esta anomalía.

## 3 Marco Teórico

### 3.1. Mercado Financiero

Los mercados en el ámbito económico son intercambios entre agentes económicos, compradores y vendedores.

Los mercados financieros son espacios donde los agentes económicos, oferentes y demandantes, llevan a cabo la negociación de diversos activos financieros. Su objetivo principal es reunir compradores y vendedores para iniciar el proceso de inversión. Dentro de este mercado existen sub-mercados los cuales se diferencian por sus estructuras, activos, fases de negociación, entre otros.

Según las características de los activos negociados, los mercados financieros se clasifican en mercados monetarios, mercados de capitales, mercados bursátiles y mercados de bonos.

El mercado de capitales es un mercado donde los activos financieros negociados presentan un nivel de riesgo más elevado y un vencimiento a medio o largo plazo. Estos activos son, por ejemplo, **las acciones** y los títulos de deuda a largo plazo. Las bolsas de valores son mercados de capitales.

En el mercado de capitales los inversores tienen la posibilidad de conseguir rentabilidades a través de las acciones adquiridas, a la vez que las empresas obtienen capital, a través de las acciones vendidas, para la financiación de capital de trabajo y proyectos de expansión (re-inversión).

Al considerar la transacción de acciones, se debe tener presente las leyes o particularidades definidas para cada mercado. Por ejemplo según Urzúa and Ph (2012) la tasa de pago de dividendos de las empresas chilenas, consideran aspectos como el pago de dividendos obligatorios, la fuerte concentración de la propiedad, las oportunidades de crecimiento, la presencia de inversionistas institucionales, entre otros.

### 3.1.1. Acciones

Las acciones son instrumentos de renta variable, emitidos por sociedades anónimas y encomandadas por acciones, que representan un título de propiedad sobre una fracción del patrimonio de la empresa, es decir, el comprador de una acción o accionista pasa a ser propietario de una parte de la empresa emisora. Desde el punto de vista de la empresa que emite las acciones, estas últimas son una alternativa de financiamiento para conseguir recursos a plazo indefinido, en tanto que desde el punto de vista del accionista, las acciones son una alternativa de ahorro a corto, mediano o largo plazo, o bien a plazo indefinido, según sean las razones que motivan su compra (Bolsa de Santiago, s.f.).

#### 3.1.1.1. Inversión

Las empresas emiten acciones como una forma de obtener financiamiento para sus distintos proyectos y así aumentar su valor consiguiendo los fondos para reinvertir en la compañía, las expectativas sobre el valor de la firma juegan un papel importante en la decisión de inversión, así por ejemplo si este dinero se aplica prudentemente para la expansión y la mejora, debería incrementar el precio de las acciones. Es por esto que, la compañía y sus inversores dependen considerablemente el uno del otro.

Cuando una empresa cotiza en Bolsa, sus acciones pueden negociarse en el mercado bursátil; los compradores y vendedores determinan el precio de las acciones. El resultado de multiplicar el precio de la acción en el mercado por el número de acciones existentes es igual al valor bursátil o capitalización de una empresa. Este criterio es muy útil para determinar el valor real de una empresa.

Si bien se observa que la compra de acciones para la empresa representa un beneficio, ¿cuál es el beneficio que obtiene el inversor? Los motivos pueden ser de dos tipos: Control y Rentabilidad.

En el primer caso que induce a la compra de acciones está relacionado con la posibilidad de obtener el manejo de una empresa a través de la compra de paquetes importantes de acciones en el mercado. Este motivo, permite formar parte del directorio de una compañía y por esa vía participar de las principales decisiones de la empresa (Bolsa de Santiago, s.f.).

El segundo motivo que induce a la compra de acciones está relacionado con la obtención de una renta por un período de tiempo determinado. Esta renta puede provenir de variaciones de precios y/o dividendos. La utilidad que proviene de las variaciones de precios recibe el nombre

de ganancia de capital y, en la mayoría de los casos, es el componente principal de la rentabilidad obtenida en el mercado de acciones. Los dividendos también inciden en la rentabilidad, ya que estos corresponden a distribuciones periódicas que efectúan las compañías de la utilidad de un ejercicio determinado (Bolsa de Santiago, s.f.). Estos últimos puntos dependen de la política de dividendos que defina cada firma.

### **3.1.2. Políticas de Dividendo**

Cualquier pago directo de la corporación a los accionistas forma parte de la política de dividendos. El objetivo principal del equipo directivo de la empresa consiste en maximizar el valor de la misma para sus accionistas, se busca encontrar aquella política que haga máximo el valor de mercado de las acciones (Mascareñas, 2011). Según la política definida por la firma, el inversionista podría re-comprar acciones, o recibir su pago en forma de dividendo.

#### **3.1.2.1. Dividendo**

El término dividendo usualmente se refiere a distribución en efectivo de utilidades. Esta distribución es hecha a partir de utilidades corrientes o utilidades acumuladas retenidas. Ya que se paga dinero en efectivo, un dividendo representa una liquidación parcial de la firma. Consecuentemente, se tiene un valor menor de la firma para los accionistas después del pago de un dividendo. Un dividendo en acciones es un tipo de dividendo pagado en acciones de capital. No es un verdadero dividendo, debido a que ningún efectivo sale de la firma (Núñez et al., 2013).

En base a lo anterior se define que la firma puede pagar un dividendo con dinero en efectivo o re-compra de acciones, dependiendo de su política.

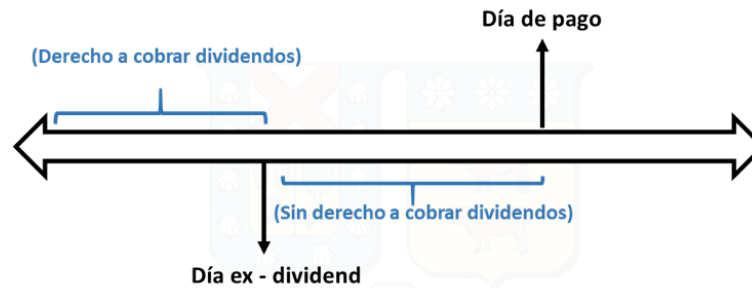
Tendrán derecho a cobrar dividendos todos los accionistas que tengan acciones antes de la fecha .<sup>ex</sup>-dividendo.<sup>o</sup> de cierre, quienes adquieran acciones en la fecha de cierre o después, no tendrán derecho a cobro de dividendos. Debemos saber que los dividendos se pagan en la fecha de pago a todos los accionistas que estén registrados en el momento de la fecha de cierre.

#### **3.1.2.2. Ganancia de Capital**

Es la diferencia entre el precio que se pagó como inversión inicial y el precio que se obtiene al vender. Se habla de ganancia cuando el valor de la venta es mayor.

### 3.1.3. Fechas de interés

Para llevar a cabo una buena estrategia de dividendos es importante comprender cómo funciona el mecanismo mediante el cual se recibe el pago de dividendos, y tener en cuenta todas las fechas importantes en el proceso.



**Figura 3.1:** Fechas de interés (Fuente: Elaboración Propia)

Los dividendos no se reparten en fechas concretas, depende de cada firma. Es por esto que se recomienda tener conocimiento de las acciones a comprar.

### 3.1.4. Índices accionarios

Para observar y comparar la variación del precio o las rentabilidades de las acciones transadas en la Bolsa de Valores, se utilizan diferentes índices accionarios que las clasifican.

Los índices bursátiles muestran la variación del valor de un conjunto de instrumentos que componen el respectivo índice, tales como acciones, títulos de deuda, entre otros.

Estos indicadores son usados principalmente por las bolsas de valores como referencia para medir la evolución del mercado, de un segmento de mercado, industria u otro. Los índices bursátiles también son usados como benchmark para medir el desempeño de carteras de activos administradas por gestores de mercado.

Los instrumentos que conforman el índice por lo general tienen características comunes, como pertenecer a una misma bolsa, tener una capitalización bursátil similar o pertenecer a un mismo tipo de industria.

En Chile, la Bolsa de Comercio de Santiago y la Bolsa Electrónica de Chile cuentan con distintos índices que buscan reflejar y medir el comportamiento que han tenido los valores transados en ellas (superintendencia de valores y seguros).

En el caso de Chile, los principales índices accionarios de la bolsa de Santiago son el Índice de Precios Selectivos de Acciones (IPSA) y el índice General de Precios de Acciones (IGPA).

#### **3.1.4.1. S&P/CLX IPSA**

El Índice de Precios Selectivo de Acciones (IPSA) está diseñado para medir los resultados de las compañías más líquidas del mercado chileno que están listadas en la Bolsa de Comercio de Santiago. En este sentido, el IPSA es considerado como el mejor indicador de resultados del mercado chileno de acciones (Bolsa Comercio Santiago, 2016).

Hasta hace unos meses estaba constituido por las 40 acciones más líquidas del Mercado, sin embargo este índice fue remplazado por el nuevo índice de la Bolsa de Santiago S&P/CLX IPSA, en el cual disminuye el número de acciones que lo conforma, dejando un máximo de 30 acciones y un mínimo de 25, esto con el objetivo que le IPSA pase de ser el índice general de mercado al invertible.

Según El mercurio inversiones (2018) el nuevo índice, que entro en régimen desde el 21 septiembre tras un acuerdo firmado entre Bolsa de Santiago y el proveedor global de índices S&P Dow Jones, no sólo implicará un cambio de nombre, también tendrá una metodología distinta de cálculo consistente con las que usa la firma neoyorquina y el cual generará importantes modificaciones frente a la composición y ponderados actuales. Se enfocará en acciones de mayor liquidez y dejará afuera a 10 acciones del actual índice.

#### **3.1.4.2. S&P/CLX IGPA**

El Índice General de Precios de Acciones (IGPA) agrupa a la gran parte de las acciones transadas en la Bolsa de Comercio de Santiago, es el índice más antiguo del mercado y constituye uno de los principales indicadores del mercado accionario chileno.

Este indicador, como es intuitivo, también se ve afectado por el nuevo acuerdo firmado entre Bolsa de Santiago y el proveedor global de índices SP Dow Jones, en donde el IGPA sustentará la nomenclatura S&P/CLX IGPA y el criterio de elegibilidad requerirá presencia bursátil de las compañías listadas en Bolsa de al menos 25 % (Emol, 2018). Este nuevo índice se volverá el índice general para el mercado chileno.

Para la inversión de las acciones, el inversor siempre busca su nivel óptimo de rentabilidad

v/s riesgo, para esto espera contar con la información necesaria para su toma de decisiones. Sin embargo, hay ciertas anomalías en el precio de las acciones que no tienen un fundamento teórico y que no son predecibles por modelos.



## 3.2. Efecto ex-dividend day

El comportamiento de los valores de las acciones siempre ha sido foco de estudio y de búsqueda de modelos para interpretar y proyectar su comportamiento, generando una base mayor para la toma de decisiones de inversión por diversos agentes del mercado. Dentro de algunos estudios se han evidenciado ciertas anomalías que frecuentemente aparecen en los mercados, principalmente en los accionarios (Kristjanpoller, 2015).

En un mercado de capital perfecto, el precio de la acción después de un dividendo debería caer exactamente por el monto del dividendo pagado en cada acción. Sin embargo, los trabajos empíricos sobre este tema generalmente encuentran que, en promedio, los precios de las acciones en nuestro mundo menos perfecto caen por debajo del monto del dividendo en la fecha ex dividendo (Castillo and Jakob, 2006).

Autores presentan distintas explicaciones para este fenómeno, la explicación más popular para esta anomalía es la hipótesis de clientes tributarios, las tasas impositivas, entre otras.

### 3.2.1. Causas

Si bien no existe una causa directa para este efecto, se han estudiado posibles factores que intervengan.

Según Elton and Gruber (1970) el comportamiento ex dividendo de las acciones de una corporación debe estar relacionado con las tasas de impuestos de sus accionistas marginales.

Un accionista que vende acciones antes de que una acción este en el día ex -dividendo pierde el derecho al dividendo ya declarado. Si vende las acciones en el día sin dividendo, conserva el dividendo, pero debería esperar venderlo a un precio inferior (debido a esta retención de dividendos). En un mercado racional la caída en el precio en el día ex - dividend debe reflejar el valor de los dividendos de ganancias de capital a los accionistas marginales. Dado que los dividendos y ganancias de capital están sujetas a impuestos a tasas diferentes, la tasa de impuesto relativo en estos dos tipos de ingresos afecta a la decisión.

A partir de la premisa de que el accionista desea maximizar su riqueza después de impuestos se puede derivar una expresión entre el día ex-dividendo y el comportamiento de las tasas de impuestos a los accionistas.

Sea:

- $P_{cum}$ =Precio en el día antes de que la acción salga ex-dividendo.
- $P_{ex}$ =Precio de la acción en el día SIN dividendos.
- $P_C$ = Precio de la acción al cual fue comprado.
- $t_0$ = Tasa de impuesto sobre la renta ordinaria.
- $t_c$ = La tasa de impuesto sobre las ganancias de capital.
- $D$ =Monto del dividendo.

Si un accionista fuera a vender sus acciones en una corporación antes de que salga ex - dividendo, su riqueza por acción sería igual al precio que recibe por la acción ( $P_{cum}$ ) menos el impuesto que debe pagar sobre cualquier ganancia de capital incurrida por poseer la acción ( $t_c(P_{cum} - P_C)$ ).

Si tuviera que vender en el día ex – dividend de la acción, su riqueza por acción sería igual al dividendo ( $D$ ) multiplicado por uno menos su tasa impositiva marginal sobre el ingreso ordinario ( $1 - t_0$ ) más la devolución después de impuestos del venta de la acción ( $P_{ex} - t_c(P_{ex} - P_C)$ ). Para que a él le sea indiferente al momento de su venta, la riqueza recibida de cualquiera de los dos casos debe ser la misma.

Es decir:

$$P_{cum} - t_c(P_{cum} - P_C) = P_{ex} - t_c(P_{ex} - P_C) + D(1 - t_0) \quad (3.1)$$

Reordenando se tiene:

$$\frac{(P_{cum} - P_{ex})}{D} = \frac{(1 - t_0)}{(1 - t_c)} \quad (3.2)$$

Según lo descrito anteriormente, el ratio caída de precio sobre dividendo dependería solo de las tasas impositivas de ambos retornos.

Además de esta causa, existen otras variables que alteran la decisión del inversor, como las expectativas o influencia de noticias y actualidad, lo cual no puede ser modelado matemáticamente.

### 3.2.2. Indicadores

Para el análisis del exdividend day existen diferentes indicadores que relacionan la caída de precio con el dividendo pagado y pueden dar visibilidad de este efecto.

Según estudios realizados por (Castillo and Jakob, 2006) para verificar el fenómeno del ex – dividend day, se deben utilizar diferentes estadísticos de prueba:

- UR: Refleja el valor relativo de los dividendos frente a las ganancias de capital.

$$UR = \frac{P_{cum} - P_{ex}}{D} \quad (3.3)$$

- AMR: Es la relación ajustada por mercado del indicador UR, para este caso se considera el IPSA como el indicador de mercado al representar, para la fecha en estudio, las acciones más negociadas del país.

$$AMR = \frac{P_{cum} \left[ 1 + \left[ \frac{IPSA_{ex} - IPSA_{cum}}{IPSA_{cum}} \right] \right] - P_{ex}}{D} \quad (3.4)$$

- AR: Adicional a estos dos indicadores, se incluye un tercero complementario, que representa la rentabilidad anormal de una acción. Se define como:

$$AR = \frac{P_{ex} - P_{cum} + D}{P_{cum}} - E(R) \quad (3.5)$$

Este indicador representa la rentabilidad de la acción menos la rentabilidad esperada, la cual es calculada mediante el modelo CAPM, pero en base al estudio de Castillo and Jakob (2006), la rentabilidad esperada se calcula considerando los precios del IPSA, con el supuesto que las acciones deben comportarse de forma similar al estar incluidos en este indicador. Por lo que se puede reescribir como:

$$AR = \frac{P_{ex} - P_{cum} + D}{P_{cum}} - \frac{IPSA_{ex} - IPSA_{cum}}{IPSA_{cum}} \quad (3.6)$$


Donde  $P_{cum}$  es el precio del día antes de estar sin dividendo,  $P_{ex}$  es el precio del día ex dividendo,  $D$  es el monto del dividendo,  $IPSA_{cum}$  corresponde al precio del IPSA antes del día ex dividend y  $IPSA_{ex}$  es el precio del día ex dividend (Castillo and Jakob, 2006) para

todos los indicadores señalados anteriormente.

Para el cálculo de la rentabilidad de las acciones y desde la perspectiva del accionista, para cualquier periodo considerado se tiene que (Núñez et al., 2013).

$$Rent_t = \frac{P(t+1) - P(t) + D}{P(t)} \quad (3.7)$$

Donde:



**Figura 3.2:** Relación entre la rentabilidad por ganancia de capital y el dividendo pagado

En donde se relaciona la rentabilidad por ganancia de capital y el dividendo pagado de la acción correspondiente.

Para este estudio en particular se consideraran dos rentabilidades, que se diferencian por el instante de tiempo en el cual son medidas.

- Rentabilidad de la acción antes que esta salga ex-dividend:

$$Rent_{antes} = \frac{P_b - P_c}{P_c} \approx \ln\left(\frac{P_b}{P_c}\right) \quad (3.8)$$

- Rentabilidad en el día exdividend:

$$Rent_{despus} = \frac{P_a - P_c + D}{P_c} \approx \ln\left(\frac{P_a + D}{P_c}\right) \quad (3.9)$$

En donde  $P_b$  es el precio antes que la acción salga ex dividend,  $P_a$  es el precio de la acción

en el día ex dividend y  $P_c$  es el precio de compra, que en este caso se considera como el precio que tuvo la acción en la fecha del dividendo anterior.

El rendimiento ex-dividendo es el obtenido en una estrategia de captura de dividendos, consistente en comprar una acción el día bursátil inmediatamente anterior a la fecha ex-dividendo, conocido como último día cum-dividendo, adquiriendo así el derecho a recibir el dividendo, y vendiendo la acción en el día ex-dividendo. Desde el punto de vista de un especulador, si en promedio la suma del precio del día ex-dividendo más el dividendo es significativamente mayor que el precio de compra se tendrá una rentabilidad extra (Arroyave C and Agudelo R, 2012).

Al revisar la literatura sobre este efecto a nivel mundial, se presenta un estudio realizado en Colombia para los 2001 al 2007, señalan que el rendimiento ex-dividendo al cierre es mayor que el obtenido a la apertura (cum-day), pero a su vez involucran un mayor riesgo, como es de esperarse al asumir el riesgo de la variación intradiaria del precio. En donde engloban el efecto de la fusión de las tres bolsas de valores en 2001.

En Estados Unidos, también se investiga el tema. Elton and Gruber (1970) en *Marginal Stockholder Tax Rates and the Cliente Effect* examinan el comportamiento de todas las acciones listadas en la Bolsa de Nueva York que pagaron un dividendo durante el período comprendido entre el 1 de abril de 1966 y el 31 de marzo de 1967, y se negociaron tanto en el día sin dividendo como en el día anterior. Con esta data, desarrollan los estadísticos de caída precio, ajustado y no ajustado, en los cuales obtienen resultados menores a uno en ambos casos. Esto muestra una preferencia por la ganancia de capital por parte del inversionista, lo cual es congruente con la situación de EEUU, en donde no existe un mínimo de dividendos pagados por las empresas, permitiendo que estas tengan más financiamiento para su crecimiento y así puedan aumentar el valor de su firma.

### 3.3. Inteligencia artificial

La inteligencia artificial, definida como “el estudio de como programar computadoras que posean la facultad de hacer aquello que la mente humana pueda realizar”, toma un sentido científico viable durante la segunda mitad del siglo 20, como resultado directo de la confluencia de diversas corrientes intelectuales desarrolladas sobre los cimientos formales de la lógica y la matemática discreta, e impulsada por el desarrollo de los computadores digitales. Particularmente la inteligencia artificial supone un serio esfuerzo por entender la complejidad de la conducta humana en términos de proceso de información (Galipienso et al., 2003).

Además se debe mencionar que la inteligencia artificial es una ciencia que incorpora conocimiento a los procesos o actividades para que estos sean exitosos. Son diversas las áreas en las que hoy está presente, algunas de estas son (Galipienso et al., 2003):

- Tratamiento de lenguas naturales: Aplicaciones de traducción de idiomas, interfaces hombre-maquina para interrogantes de bases de datos o dar ordenes a un sistema operativo. En resumen, hacer la comunicación más amigable para el usuario.
- Sistemas expertos: Conseguir deducciones más cercanas a la realidad en base a experiencias personales.
- Robótica: Robots móviles, control y ensamblaje de piezas.
- Problema de percepción, reconocimiento de objetos, habla, defectos en piezas, etc.
- Aprendizaje: Modelización de conductas para su posterior implementación en computadoras.
- Finanzas: Percepción de las componentes no lineales de la series de tiempo.

Las Redes Neuronales son un campo muy importante dentro de la Inteligencia Artificial. Inspirándose en el comportamiento conocido del cerebro humano, principalmente el referido a las neuronas y sus conexiones, trata de crear modelos artificiales que solucionen problemas difíciles de resolver mediante técnicas algorítmicas convencionales.

### 3.3.1. Redes neuronales artificiales (RNA)

Una red neuronal es un sistema que permite establecer una relación lineal o no lineal entre las salidas y las entradas. Sus características están inspiradas en el sistema nervioso lo que les da varias ventajas tales como su capacidad de aprendizaje adaptativo, son auto-organizativas, pueden funcionar en paralelo en tiempo real y ofrecen tolerancia a fallos por la codificación redundante de la información.

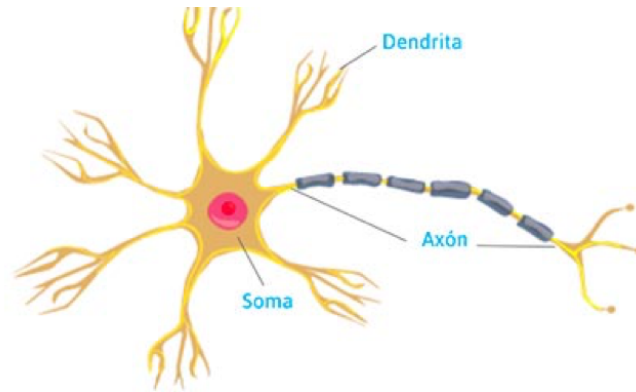
Desde el punto de vista de solucionar problemas, las redes neuronales son diferentes de los computadores convencionales que usan algoritmos secuenciales, mientras que las redes neuronales actúan como el cerebro humano, procesando la información en paralelo, y también pueden aprender y generalizar a situaciones no incluidas en el proceso de entrenamiento. Las redes neuronales pueden procesar información de forma más rápida que los computadores convencionales, pero tienen la desventaja de que no podemos seguir su respuesta paso a paso como se puede hacer al ejecutar un programa convencional en un ordenador por lo que no resulta fácil detectar los errores.

Las Redes Neuronales Artificiales han sido empleadas para resolver numerosos problemas. Entre estos están los económicos y financieros, destacando en gran medida su aplicación en la predicción de series temporales y su capacidad para detectar y explotar la no-linealidad existente en los datos, aún en condiciones donde existen datos incompletos o la presencia de ruido; también se destacan por su desempeño en la solución de problemas complejos, donde el reconocimiento de modelos o comportamientos es importante (Villada and Muñoz, 2012).

#### 3.3.1.1. Neurobiología

Las neuronas presentan unas características morfológicas típicas que sustentan sus funciones: un cuerpo celular, llamado soma central, una o varias prolongaciones cortas que generalmente transmiten impulsos hacia el soma celular, denominadas dendritas; y una prolongación larga, denominada axón, que conduce los impulsos desde el soma hacia otra neurona.

Típicamente, las neuronas son 6 ó 5 órdenes de magnitud más lentas que una compuerta lógica, los eventos en un chip de silicio toman alrededor de nanosegundos, mientras que en una neurona este tiempo es del orden de milisegundos. Sin embargo, el cerebro compensa esta lentitud relativa en el funcionamiento neuronal con un número inmenso de neuronas con interconexiones entre ellas. Se estima que el número de neuronas en el cerebro es del orden de  $10^{10}$  y el número de



**Figura 3.3:** Representación Neurona. Extraído de: [www.down21.org](http://www.down21.org)

conexiones sinápticas son del orden  $10^{13}$ .

A modo de comparación se tiene que:

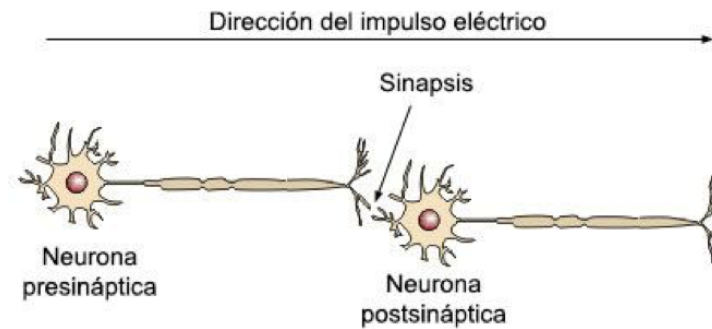
**Tabla 3.1:** Comparación cerebro humano y computador

Características	Cerebro Humano	Computador
Velocidad de proceso	Entre $10^{-3}$ y $10^{-2}$ seg	Entre $10^{-8}$ y $10^{-9}$ seg
Estilo de procesamiento	Paralelo	Secuencial
Número de procesadores	Entre $10^{11}$ y $10^{14}$	Pocos
Conexiones	10.000 por procesador	Pocos
Almacenamiento del conocimiento	Distribuido	En direcciones fijas
Tolerancia a fallos	Amplia	Poca o nula
Tipo de control del proceso	Auto organizado	Centralizado
Consumo de energía para ejecutar una operación J/s	$10^{-16}$	$10^{-6}$

En base a lo anterior es que el cerebro es una estructura enormemente eficiente. La eficiencia energética de esta estructura es  $10^{10}$  veces mayor que los mejores computadores en la actualidad (López and Fernandez, 2008).

La mayoría de las neuronas codifican sus salidas como una serie de periodos llamados potenciales de acción, que se originan cercanos al soma de la célula y se propagan a través del axón. Luego, este pulso llega a las sinapsis y de ahí a las dendritas de la neurona siguiente. Una sinapsis es una interconexión entre dos neuronas. En ella el botón sináptico corresponde al término del axón de una neurona pre-sináptica y la dendrita es la correspondiente a una neurona post-sináptica.

El tipo más común de sinapsis es la sinapsis química. Una señal neural eléctrica pre-sináptica,



**Figura 3.4:** Representación sinapsis. Extraído de: <https://www.psicooactiva.com/blog/la-sinapsis-neuronal-tipos-sinapsis/>

llega al botón sináptico, allí hace que las vesículas sinápticas se rompan, liberando una sustancia llamada neurotransmisor. Esta sustancia se difunde a través del espacio entre las neuronas. Luego es captada por la dendrita en donde estimula la emisión de un nuevo impulso eléctrico, post-sináptico, que se propaga hacia la derecha. Las dendritas son las zonas receptoras de una neurona, siendo el axón una línea de transmisión, y los botones terminales comunican los impulsos a otras neuronas.

En la neurona, hay dos comportamientos que son relevantes para el caso en estudio:


El impulso que llega a una sinapsis y el que sale de ella no son iguales en general. El tipo de pulso que saldrá depende de la cantidad de neurotransmisor, la cual cambia durante el proceso de aprendizaje, es donde se almacena la información. Una sinapsis modifica el pulso, ya sea para reforzarlo o debilitarlo.

En el soma se suman las entradas de todas las dendritas, si sobrepasan cierto umbral, se transmitirá un pulso a lo largo del axón, en caso contrario no transmitirá.

### 3.3.1.2. Modelos Neuronales

Los modelos neuronales, están compuestos por capas, neuronas, pesos y procesos que ocurren dentro. Teniendo  $n$  neuronas de interés  $x_i$  enviando señales de entrada, la neurona de interés  $y_j$ , se define el peso sináptico en las dendritas  $y_j$  como  $w_{ji}$ . El primer índice denota la neurona hacia donde se dirige la información, el segundo índice denota de qué neurona procede la información (Izaurieta).

Cada peso sináptico representa la importancia relativa de cada entrada.




**Figura 3.5:** Representación sinapsis. Extraído de: Redes Neuronales artificiales (Izaurieta)

Ya que en el soma de la neurona biológica se sumaban las entradas provenientes de todas las dendritas, entonces se tiene que la entrada total a la neurona  $y_j$  es la suma producto de todas las entradas que se dirigen a esta neurona con sus pesos respectivos:

$$Y_j^{(in)} = \sum_{i=1}^n w_{ji}x_i \quad (3.10)$$

En donde el índice  $(in)$  representa “input” o entrada a la neurona.

Como se mencionó anteriormente, la neurona se activa si la entrada total supera un cierto umbral. Lo que se hace para esto es aplicar una función de activación sobre  $y_j^{(in)}$ .



**Figura 3.6:** Activación neurona. Extraído de: <https://ernestocrespo13.files.wordpress.com>


### 3.3.1.3. Función de activación

La función activación calcula el estado de actividad de una neurona; transformando la entrada global menos el umbral en un valor (estado) de activación, cuyo rango normalmente va de (0 a 1) o de (-1 a 1). Esto es así, porque una neurona puede estar totalmente inactiva (0 o -1) o activa (1). Las funciones de activación más comúnmente utilizadas son:

- Función lineal:

$$f(x) = \begin{cases} -1 & \text{si } x \leq -1/a \\ a * x & \text{si } -1/a < x < 1/a \\ 1 & \text{si } x \geq 1/a \end{cases} \quad (3.11)$$

Donde  $x$  es la diferencia entre la entrada global, y el umbral, “ $a$ ” es una constante mayor que 0, si  $a=1$  se tiene la gráfica lineal típica:



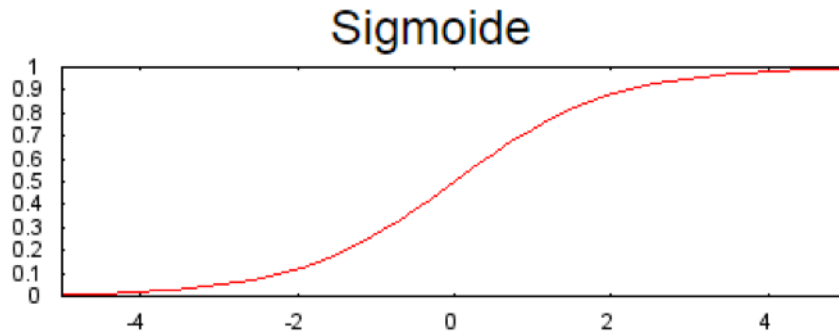
**Figura 3.7:** Función de activación lineal. Extraído de: <https://www.researchgate.net>

Los valores de salida obtenidos por medio de esta función se observan en la ecuación 3.11. En el caso de  $a=1$  la salida es igual a la entrada.

- Función Sigmoidea:

$$f(x) = \frac{1}{1 + e^{-gx}} \quad (3.12)$$

Donde  $x$  es la diferencia entre la entrada global y el umbral,  $g$  representa la pendiente de la función. Los valores de salida que proporciona esta función, están comprendidos dentro de un rango que va de 0 a 1. Al modificar el valor de  $g$  se ve afectada la pendiente de la función de activación.



**Figura 3.8:** Función de activación sigmoidea. Extraído de: <https://developers.google.com/machine-learning/crash-course/introduction-to-neural-networks/anatomy?hl=es-419>

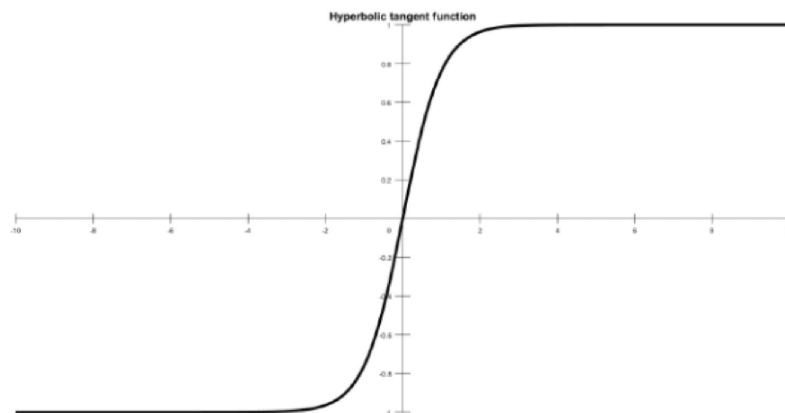
- Función tangente hiperbólica:

$$f(x) = \frac{e^{gx} - e^{-gx}}{e^{gx} + e^{-gx}} \quad (3.13)$$

Donde  $x$  es la diferencia entre la entrada global y el umbral,  $g$  representa la pendiente de la función.

Los valores de salida de la función tangente hiperbólica están comprendidos dentro de un rango que va de -1 a 1. Al modificar el valor de  $g$  se ve afectada la pendiente de la función de activación.

La principal diferencia con la función de activación sigmoidea, es el rango de salida, ya que este se expande de -1 a 1.



**Figura 3.9:** Función de activación tangente hiperbólica. Extraído de: [https://www.researchgate.net/figure/Figura-17-Funcion-de-activacion-de-tangente-hiperbolica\\_fig20\\_28600321](https://www.researchgate.net/figure/Figura-17-Funcion-de-activacion-de-tangente-hiperbolica_fig20_28600321)

El último componente que una neurona necesita es la función de salida. El valor resultante de esta función es la salida de la neurona  $y_j$ ; por ende, la función de salida determina que valor se transfiere a las neuronas vinculadas. Si la función de activación está por debajo de un umbral determinado, ninguna salida se pasa a la neurona subsiguiente. Normalmente, no cualquier valor es permitido como una entrada para una neurona, por lo tanto, los valores de salida están comprendidos en el rango  $[0, 1]$  o  $[-1, 1]$ . También pueden ser binarios  $\{0, 1\}$  o  $\{-1, 1\}$ .

#### 3.3.1.4. Neurona

Las neuronas y las conexiones entre ellas (sinapsis) constituyen la clave para el procesado de la información. La mayor parte de las neuronas poseen una estructura de árbol, llamada dendritas, que reciben las señales de entrada procedentes de otras neuronas a través de las sinapsis. Una neurona consta de tres partes:

- El cuerpo de la neurona.
- Las dendritas, que reciben las entradas.
- El axón, que lleva la salida de la neurona a las dendritas de otras neuronas.

La forma completa en la que dos neuronas se relacionan no es totalmente conocida, y depende además del tipo particular de cada neurona. En general, una neurona envía su salida a otras por su axón, y éste lleva la información por medio de diferencias de potencial eléctrico.

Las neuronas artificiales se pueden clasificar de acuerdo a los valores que pueden tomar. Por ahora es suficiente distinguir entre dos tipos principales:


- Neuronas binarias.
- Neuronas reales.

Las neuronas binarias solamente pueden tomar valores dentro del intervalo  $\{0, 1\}$  o  $\{-1, 1\}$ , mientras que las neuronas reales pueden hacerlo dentro del rango  $[0, 1]$  o  $[-1, 1]$ . Los pesos normalmente no están restringidos a un cierto intervalo, aunque para aplicaciones específicas puede ser esto necesario. (Marín Diazaraque, 2007).

### 3.3.1.5. Capas

La distribución de neuronas dentro de la red se realiza formando niveles o capas, con un número determinado de dichas neuronas en cada una de ellas. A partir de su situación dentro de la red, se pueden distinguir tres tipos de capas Redes Neuronales (Damian Jorge Matich, 2001):

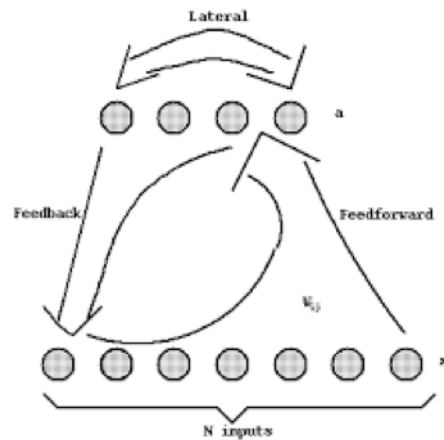
- **De entrada:** es la capa que recibe directamente la información proveniente de las fuentes externas de la red.
- **Ocultas:** son internas a la red y no tienen contacto directo con el entorno exterior. El número de niveles ocultos puede estar entre cero y un número elevado. Las neuronas de las capas ocultas pueden estar interconectadas de distintas maneras, lo que determina, junto con su número, las distintas topologías de redes neuronales.
- **De salida:** transfieren información de la red hacia el exterior.



**Figura 3.10:** Diagrama red neuronal, capas. Extraído de: Redes Neuronales: Conceptos Básicos y Aplicaciones (Damian Jorge Matich, 2001)

### 3.3.1.6. Estructuras de conexión

Entre dos capas de neuronas existe una red de pesos de conexión, que puede ser, hacia delante, hacia atrás, lateral y de retardo (Marín Diazaraque, 2007).



**Figura 3.11:** Diagrama estructuras de conexión. Extraído de: <http://inteligenciaartificialudb.blogspot.com/>

- Conexiones hacia delante (Feedforward): los valores de las neuronas de una capa inferior son propagados hacia las neuronas de la capa superior por medio de las redes de conexiones hacia adelante.
- Conexiones hacia atrás (Feedback): estas conexiones llevan los valores de las neuronas de una capa superior a otras de la capa inferior.
- Conexiones laterales: Un ejemplo típico de este tipo es el circuito “el ganador toma todo” (winner-takes-all), que cumple un papel importante en la elección del ganador: a la neurona de salida que da el valor más alto se le asigna el valor total, mientras que a todas las demás se le da un valor de 0.
- Conexiones con retardo: los elementos de retardo se incorporan en las conexiones para implementar modelos dinámicos y temporales, es decir, modelos que precisan de memoria.

### 3.3.1.7. Fases

Hay dos fases en la modelización con redes neuronales:

1. Fase de entrenamiento: se usa un conjunto de datos o patrones de entrenamiento para determinar los pesos (parámetros) que definen el modelo de red neuronal. Se calculan de manera iterativa, de acuerdo con los valores de los valores de entrenamiento, con el objeto de minimizar el error cometido entre la salida obtenida por la red neuronal y la salida deseada.

En otras palabras el aprendizaje es el proceso por el cual una red neuronal modifica sus pesos

en respuesta a una información de entrada. Los cambios que se producen durante el mismo se reducen a la destrucción, modificación y creación de conexiones entre las neuronas. En los sistemas biológicos existe una continua destrucción y creación de conexiones entre las neuronas. En los modelos de redes neuronales artificiales, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero. De la misma manera, una conexión se destruye cuando su peso pasa a ser cero.

Durante el proceso de aprendizaje, los pesos de las conexiones de la red sufren modificaciones, por lo tanto, se puede afirmar que este proceso ha terminado (la red ha aprendido) cuando los valores de los pesos permanecen estables

2. Fase de Prueba: en la fase anterior, el modelo puede que se ajuste demasiado a las particularidades presentes en los patrones de entrenamiento, perdiendo su habilidad de generalizar su aprendizaje a casos nuevos (sobreajuste). Para evitar el problema del sobreajuste, es aconsejable utilizar un segundo grupo de datos diferentes a los de entrenamiento, el grupo de validación, que permita controlar el proceso de aprendizaje.

#### **3.3.1.8. Aprendizaje**

Un aspecto importante respecto al aprendizaje de las redes neuronales es el conocer cómo se modifican los valores de los pesos, es decir, cuáles son los criterios que se siguen para cambiar el valor asignado a las conexiones cuando se pretende que la red aprenda una nueva información. Hay dos métodos de aprendizaje importantes que pueden distinguirse (Damian Jorge Matich, 2001).

- Aprendizaje supervisado.
- Aprendizaje no supervisado.

#### **3.3.1.9. Aprendizaje supervisado**

El aprendizaje supervisado se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor, maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor controla la salida de la red y en caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida

obtenida se aproxime a la deseada.

### **3.3.1.10. Aprendizaje no supervisado**

Las redes con aprendizaje no supervisado (también conocido como auto-supervisado) no requieren influencia externa para ajustar los pesos de las conexiones entre sus neuronas. La red no recibe ninguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es o no correcta. Estas redes deben encontrar las características, regularidades, correlaciones o categorías que se puedan establecer entre los datos que se presenten en su entrada. Existen varias posibilidades en cuanto a la interpretación de la salida de estas redes, que dependen de su estructura y del algoritmo de aprendizaje empleado.

## **3.3.2. Tipos de redes neuronales**

### **3.3.2.1. Red monocapa**

Esta red corresponde a la más sencilla, ya que solo contiene 2 tipos de capas de neuronas: de entrada, recibiendo los inputs y la capa de salida.

### **3.3.2.2. Red multicapa**

Para esta configuración existe un conjunto de capas intermedias (ocultas) entre la capa de entrada y salida, y es en estas capas ocultas donde se procesa la información y se realizan las funciones internas.

## 3.4. Modelos econométricos

Una de las opciones más comunes para realizar pronósticos en la economía es a través del empleo de modelos econométricos, los cuales presentan una serie de variables independientes o exógenas, las que buscan explicar una variable endógena, donde las variables explicativas pueden ser incluso, la misma variable endógena pero rezagada, lo cual es ocupado cuando se busca explicar el comportamiento de una variable a partir del comportamiento de esta misma en periodos pasados.

Estas variables son acompañadas de parámetros mediante una formulación matemática y análisis estadístico que dan lugar a una estimación numérica de dichos parámetros, los cuales permiten realizar una proyección de los valores futuros de la serie de tiempo.

### 3.4.1. Series de tiempo

#### 3.4.1.1. Concepto de estacionalidad

Un tipo de proceso estocástico que ha recibido gran atención y ha sido objeto de escrutinio por parte de los analistas de series de tiempo es el proceso estocástico estacionario. En términos generales, se dice que un proceso estocástico es estacionario si su media y su varianza son constantes en el tiempo y si el valor de la covarianza entre dos periodos depende sólo de la distancia o rezago entre estos dos periodos, y no del tiempo en el cual se calculó la covarianza. En la bibliografía sobre series de tiempo, un proceso estocástico como éste se conoce como proceso estocástico débilmente estacionario, estacionario covariante, estacionario de segundo orden o proceso estocástico en amplio sentido (Gujarati and Porter). Para efectos de esta memoria, y en la mayoría de las situaciones prácticas, se considera que la serie de las rentabilidades es estacionaria, a diferencia de lo que sucede usualmente con la serie de los precios.

En resumen, si una serie de tiempo es estacionaria, su media, su varianza y su autocovarianza (en los diferentes rezagos) permanecen iguales sin importar el momento en el cual se midan; es decir, son invariantes respecto del tiempo. Tal serie de tiempo tenderá a regresar a su media (llamada reversión media) y las fluctuaciones alrededor de esta media (medida por su varianza) tendrán una amplitud constante en términos generales. Por el contrario, si una serie de tiempo no es estacionaria en el sentido antes definido, se denomina serie de tiempo no estacionaria. En otras palabras, una serie de tiempo no estacionaria tendrá una media que varía con el tiempo o una

varianza que cambia con el tiempo, o ambas.

¿Por qué las series de tiempo estacionarias son tan importantes? Porque si una serie de tiempo es no estacionaria, sólo se puede estudiar su comportamiento durante el periodo en consideración. Por tanto, cada conjunto de datos perteneciente a la serie de tiempo corresponderá a un episodio particular. En consecuencia, no es posible generalizar para otros periodos. Así, para propósitos de pronóstico, tales series de tiempo (no estacionarias) tienen poco valor práctico, es por esto que para los fines que persigue esta memoria es necesario trabajar con series de tiempo estacionales, de acuerdo al sentido anteriormente definido.

### 3.4.1.2. Proceso autorregresivo (AR)

Sea  $Y_t$  por ejemplo, una serie de tiempo que represente la rentabilidad de una determinada acción en el periodo  $t$ . Si se modela  $Y_t$  como

$$(Y_t - \delta) = \alpha_1(Y_{t-1} - \delta) + \alpha_2(Y_{t-2} - \delta) + \dots + \alpha_p(Y_{t-p} - \delta) + u_t \quad (3.14)$$

donde  $\delta$  es la media de  $Y$  y  $u_t$  es un término de error aleatorio no correlacionado con media cero y varianza constante  $\sigma^2$  (es decir, ruido blanco), se dice que  $Y_t$  sigue un proceso estocástico autorregresivo de orden  $p$ , o AR( $p$ ). Aquí el valor de  $Y$  en el tiempo  $t$  depende de su valor en los  $p$  periodos anteriores y de un término aleatorio; los valores de  $Y$  están expresados como desviaciones de su valor medio. En otras palabras, este modelo dice que el valor de pronóstico de  $Y$  en el periodo  $t$  es simplemente algunas proporciones de sus valores en los periodos anteriores más un “choque” o perturbación en el tiempo  $t$ ; de nuevo, los valores de  $Y$  están expresados alrededor del valor de su media.

### 3.4.1.3. Proceso de medias móviles (MA)

El proceso AR recién expuesto no es el único mecanismo que pudo generar  $Y$ . Suponga que se realiza un modelo de  $Y$  de la siguiente manera:

$$Y_t = \mu + \beta_0 u_t + \beta_1 u_{t-1} + \beta_2 u_{t-2} + \dots + \beta_q u_{t-q} \quad (3.15)$$

donde  $\mu$  es una constante y  $u$ , al igual que antes es el término del error estocástico de ruido

blanco. Aquí,  $Y$  en el periodo  $t$  es igual a una constante más un promedio móvil de los términos del error presentes y pasados, en este caso se dice que  $Y$  sigue un proceso de promedios móviles de orden  $q$  o  $MA(q)$ .

#### 3.4.1.4. Proceso autorregresivo y de promedios móviles (ARMA)

Desde luego, es muy probable que  $Y$  tenga características de AR y MA a la vez, por consiguiente, sea ARMA. Así,  $Y_t$  sigue un proceso ARMA( $p,q$ ) si se escribe como:

$$Y_t = \theta + \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{i=1}^q \beta_i u_{t-i} + u_t \quad (3.16)$$

donde  $\theta$  es una constante y  $u_t$  es un término de error aleatorio no correlacionado con media cero y varianza constante  $\sigma^2$ .

#### 3.4.1.5. Proceso autorregresivo integrado de promedios móviles (ARIMA)

Los modelos de series de tiempo analizados se basan en el supuesto de que las series de tiempo consideradas son (débilmente) estacionarias. En pocas palabras, la media y la varianza de una serie de tiempo débilmente estacionaria son constantes y su covarianza es invariante en el tiempo. Pero se sabe que muchas series de tiempo económicas son no estacionarias, es decir, son integradas.

Sin embargo, si una serie de tiempo es integrada de orden 1, sus primeras diferencias son  $I(0)$ , es decir, estacionarias. En forma similar, si una serie de tiempo es  $I(2)$ , sus segundas diferencias son  $I(0)$ . En general, si una serie de tiempo es  $I(d)$ , después de diferenciarla  $d$  veces se obtiene una serie  $I(0)$ .

Por consiguiente, si se debe diferenciar una serie de tiempo  $d$  veces para hacerla estacionaria y luego aplicarle el modelo ARMA( $p,q$ ), se dice que la serie de tiempo original es ARIMA( $p,d,q$ ), es decir, es una serie de tiempo autorregresiva integrada de promedios móviles, donde  $p$  denota el número de términos autorregresivos,  $d$  el número de veces que la serie debe diferenciarse para hacerse estacionaria y  $q$  el número de términos de promedios móviles.

## 3.5. Prueba estadística

Una prueba estadística es una forma de evaluar la evidencia que los datos proporcionan para probar una hipótesis. Esta hipótesis se denomina hipótesis nula, y suele denominarse  $H_0$ . Normalmente,  $H_0$  establece la igualdad (entre las medias, o entre las varianzas, o entre un coeficiente de correlación y cero).  $H_0$  normalmente se opone a una hipótesis denominada hipótesis alternativa, denominada  $H_1$  o  $H_a$ .

Se debe especificar un umbral de riesgo por encima del cual  $H_0$  no debería ser rechazada. Este umbral se conoce como nivel de significación alfa, y debería estar entre 0 y 1. Valores bajos de alfa son más conservadores. La elección de alfa debería depender de cuán peligroso sea rechazar  $H_0$  en el caso de que sea verdadera. En la mayoría de los casos, alfa se fija en 0.05, 0.01 o 0.001.

La prueba estadística produce un número denominado valor-p (cuyos límites son 0 y 1). El valor p es la probabilidad de obtener los datos bajo la hipótesis nula.

El valor p se compara con alfa de la siguiente forma:

- Si  $p < \alpha$ , rechazamos  $H_0$  y aceptamos  $H_a$  con un riesgo proporcional al valor p de ser errónea.
- Si  $p > \alpha$ , no rechazamos  $H_0$ , pero esto no implica necesariamente que debemos aceptarla. Significa que dichos resultados y prueba estadística no han sido suficientemente "fuertes" para producir un valor p inferior a alfa.

### 3.5.1. t-student

La prueba "t" de Student es un tipo de estadística deductiva. Se utiliza para determinar si hay una diferencia significativa entre las medias de dos grupos. Con toda la estadística deductiva, asumimos que las variables dependientes tienen una distribución normal.

Para esta prueba se formula la hipótesis nula y alternativa como:

- $H_0$ : La diferencia entre las medias es igual a 0.
- $H_a$ : La diferencia entre las medias es diferente de 0.

Las pruebas-t de dos muestras para probar la diferencia en las medias pueden ser relacionadas o independientes. La primera clasificación permite comparar las medias de dos series de mediciones

realizadas sobre las mismas unidades estadísticas. En cambio la segunda mencionada, se encarga de comparar dos muestras en dos grupos o poblaciones diferentes.



## 4 Metodología

### 4.1. Datos

Para este análisis se utilizan 31 acciones del mercado chileno, estas acciones son elegidas por estar dentro del 75 % más transada en bolsa, de todas las acciones pertenecientes al antiguo IPSA. De estas acciones se extraen distintos valores, como el precio de cierre, el volumen de transacción, la liquidez, la cantidad de acciones y los dividendos pagados. Todo esto considerando un intervalo de tiempo diario que comprende desde enero del 2007 a diciembre del 2018.

### 4.2. Efecto exdividend en Chile

Para la comprobación de este efecto en Chile, se muestra el procedimiento que se realizó con la data y los estadísticos calculados que revelan la presencia (o no) de este efecto en Chile.

Los estadísticos para este análisis se obtienen como:

- Caída de precio:  $P_{cum} - P_{ex}$  Siendo  $P_{cum}$  el precio promedio de la acción. Se toma el precio de cierre de los 20 días hábiles anteriores a la fecha del pago de dividendo, estos se promedian para tener una muestra más representativa, disminuyendo la probabilidad de influencia por datos atípicos. Para el caso de  $P_{ex}$ , se toma el precio de cierre del día posterior al dividendo. Todos estos datos son extraídos de la plataforma web de Investing. Una vez obtenida esta diferencia de precios, se compara con el dividendo.
- Dividendo: Div Se extraen los dividendos pagados por cada acción y sus respectivas fechas desde la página del Banco Central de Chile.

En un mercado de capital perfecto, el precio de la acción después de un dividendo debería caer exactamente por el monto del dividendo pagado en cada acción. Sin embargo, los

trabajos empíricos sobre este tema generalmente encuentran que, en promedio, los precios de las acciones en nuestro mundo menos perfecto caen por debajo del monto del dividendo en la fecha ex dividendo.

Para observar como se comporta este efecto en las acciones del mercado chileno, se presentan las principales estadísticas de la relación caída de precios a dividendos para nuestra muestra, calculados en base a la caída de precios y dividendo obtenidos anteriormente.

- Proporción no ajustada:

$$UR = \frac{P_{cum} - P_{ex}}{D} \quad (4.1)$$

Este indicador es calculado para todas las fechas donde existió pago de dividendo, luego se obtiene la media mediante estadística descriptiva. Se espera que la media sea cercana a 1, lo que comprobaría que la caída de precio es igual al monto del dividendo pagado en tal fecha. Esto se realiza para la data formada por el 75 % de las acciones más transadas en Chile.

- Proporción ajustada por el mercado:

$$AMR = \frac{P_{cum} \left[ 1 + \left[ \frac{IPSA_{ex} - IPSA_{cum}}{IPSA_{cum}} \right] \right] - P_{ex}}{D} \quad (4.2)$$

Es el mismo indicador anterior, pero por un multiplicador al precio de la acción antes del pago de dividendo (promedio de 20 días anteriores). El multiplicador es una proporción del precio de mercado, el cual para este estudio será el IPSA.

Por lo que se obtiene, de la misma forma que en las acciones, el precio del IPSA antes de la fecha de pago de dividendo de la acción ( $IPSA_{cum}$ ), promediando el precio de cierre de los 20 días hábiles, anteriores a esta fecha, para el IPSA.

Además ( $IPSA_{ex}$ ) se obtiene, sacando el precio de cierre para el IPSA, en el día después del pago de dividendo de cada acción. Teniendo todos estos datos se puede calcular el indicador AMR, el cual tendría que ser un poco mayor a 1, por el ajuste de mercado realizado a la prueba UR.

- Rendimiento anormal:

$$AR = \frac{P_{ex} - P_{cum} + D}{P_{cum}} - \frac{IPSA_{ex} - IPSA_{cum}}{IPSA_{cum}} \quad (4.3)$$

Este indicador es adicionales a los anteriores, para observar el comportamiento de la muestra y el indicador de mercado. Se estima que la diferencia sea aproximadamente 0, esto en base a la suposición que el rendimiento normal de cualquier acción debería ser igual al rendimiento del índice IPSA ese mismo día. Esta suposición se basa en el hecho de que todas las acciones de esta muestra están incluidas en este índice, que considera las acciones más negociadas en el país.

Las componentes de este indicador están detallados anteriormente.

- Dividend yield

$$Yield = \frac{Dividendo}{P_{ex}} \quad (4.4)$$

Este ratio muestra la rentabilidad del dividendo, es la relación entre los dividendos anuales por acción pagados por una compañía y el precio de sus acciones en bolsa.

Fue calculado a partir de todos los dividendos obtenidos para las acciones de la muestra, y se dividió del precio de la acción luego del día ex dividendo.

Este ratio da una visión del como va la empresa, para donde hay que invertir, y el perfil de empresa según lo que busca el inversor. Con lo anterior se concluye en base al valor obtenido por la media del ratio para todas las acciones, como conjunto representante del mercado chileno.

Una vez calculado todos los indicadores para todas las fechas en donde hubo pago de dividendo y para las 33 acciones consideradas en el estudio, se agrupan todas para obtener una única representación de mercado en base a las acciones más transadas en Chile (ya que fueron sacadas del IPSA).

Ya agrupadas se calcula la media y desviación con estadística descriptiva de Excel, de ella se extrae la media obtenida para:

- La diferencia de precio
- Dividendos

Se comparan estas dos medias, ya que se consideran las más representativas para comprobar el efecto ex dividend en Chile, ya que el supuesto indica que ambos sean iguales.

Luego se procede a revisar los resultados para los indicadores UR, AMR y AR. Se procede de la misma forma, con la data de todas las acciones agrupadas se obtiene mediante estadística

descriptiva la media de cada uno de los estadísticos, de esta forma se puede concluir sobre el efecto estudiado, con indicadores adicionales a la caída del precio y el monto del dividendo.

Finalmente se procede a concluir como se comporta este efecto con la data de prueba, para el mercado chileno y cuales pueden ser sus posibles efectos y causas.

### **4.3. Pronóstico para decisión del inversor**

Para el inversor es una gran tarea decidir en donde, cuanto y cuando va a invertir. Es por esto que en este trabajo se realiza un análisis a través de diferentes modelos de pronóstico, cual es el mejor momento de inversión, tanto si vende o compra acciones.

Se consideran 515 observaciones, obtenidas del 75 % de la acciones con más presencia bursátil de todas las acciones seleccionadas. Para esto se considera la cantidad de dividendos pagados por cada una de las acciones en el periodo de tiempo seleccionado y se elige el 75 % de acciones con más dividendos al año. Este porcentaje se escoge para que la muestra sea representativa para el trabajo en redes neuronales, debido a que inicialmente la evaluación se planeaba hacer por acción, pero los datos por acción no superaban los 50, lo que limitaba el trabajo de la red.

Las 515 observaciones vienen de las acciones:

- EMB ANDINA
- CONCHAYTORO
- SK
- SALFACORP
- BESALCO
- AESGENER
- CMPC
- CAP
- CENCOSUD
- SECURITY

- SQM-B
- FALABELLA
- SONDA
- AGUAS ANDINA
- COPEC
- IAM
- CCU
- ENTEL
- LATAM
- OROBLANCO
- COLBUN
- ITAU



Las cuales están ordenadas de mayor a menor según presencia bursátil.

Además el periodo de datos va desde el 18 de Abril del 2007 al 21 de Diciembre del 2017.

### **4.3.1. Redes Neuronales Artificiales: Aplicación**

Como se mencionó anteriormente, las redes neuronales artificiales son un sistema que permite establecer una relación lineal o no lineal entre las salidas y las entradas. Según esta definición se va a definir las entradas y salidas de la red para este trabajo:

#### **4.3.1.1. Entradas**

Los inputs para los modelos a realizar, son variables que se consideran significativas para la decisión de inversión.

- Volumen: Volumen de transacción [\$].
- Cantidad acciones: Cantidad de acciones en la bolsa cada día.

- Acciones transadas: Acciones transadas cada día.
- Liquidez Técnicas: Volumen transado por el precio de la cantidad de acciones en circulación.
- Precio del dólar.
- Día sem: Se consideran 7 variables binarias para cada día de la semana.
- Inicio mes: Binaria que reconoce si el día se encuentra dentro de los 5 primeros del mes.
- Fin de mes: Binaria que reconoce si el día se encuentra dentro de los 5 finales del mes.
- UR: Relación caída de precio y dividendo.
- Dividend Yield: Rendimiento de la acción.
- AMR: Relación caída de precio y dividendo ajustada por el mercado (IPSA).
- AR: Relación entre el rendimiento de la acción y el rendimiento del mercado.
- Dividendo: Monto del dividendo pagado.
- $P_{cum} - P_{ex}$ : Caída de precio (antes y después del día ex-dividend).
- 52WK: Ratio que relaciona el precio de la acción con el precio máximo obtenido dentro de las 52 semanas anteriores.
- Rent\_antes: Representa la rentabilidad obtenida por la acción antes que salga ex dividend. Para su calculo se considera solo la ganancia de capital, obtenida por la compra/venta de la acción.
- Rent\_después: Es la rentabilidad obtenida por la acción después que salga ex dividend. Para este caso se considera la ganancia de capital y además el dividendo obtenido.

#### 4.3.1.2. Salidas

Estos son los outputs que arroja el modelo. Se utilizan como criterio para la decisión de inversión y dependerán del modelo que se esté desarrollando. En general estas serán:

- UR: Relación caída de precio y dividendo.
- AMR: Relación caída de precio y dividendo ajustada por el mercado (IPSA).

- AR: Relación entre el rendimiento de la acción y el rendimiento del mercado.
- Rent\_antes: Representa la rentabilidad obtenida por la acción antes que salga ex dividend.
- Rent\_después: Es la rentabilidad obtenida por la acción después que salga ex dividend.

Estas salidas son el resultado de cada modelo realizado para pronóstico que ayuda a la decisión de inversión. Estos modelos serán explicados más adelante.

#### 4.3.1.3. Estructura

Además de las entradas y salidas de la red, existen otros factores que determinan el funcionamiento y estructura que tendrá la red.

Cada red neuronal artificial posee una arquitectura la cual conlleva a como se modelará la red y el rendimiento que esta obtendrá. En la arquitectura de la red se deben definir ciertos parámetros dentro de los que se encuentran generalmente el número de neuronas por capas, cantidad de capas intermedias u ocultas, pesos sinápticos iniciales, entre otros.

Para este trabajo se prueban diferentes configuraciones y se elige la que tenga mejores resultados, esto mediante la diferencia de medias entre los resultados entregados por los modelos de predicción y los resultados reales.

Las configuraciones utilizadas para todos los modelos son:

- Capas {2, 4, 6, 8}.
- Neuronas {5, 10, 15, 20, 25}.

Se realizan todas las combinaciones entre capas y neuronas, por lo que se realizan 20 pruebas por modelo.

El modelo propuesto corresponde a una red neuronal multicapa feedforward, donde su conexión o flujo de propagación de la información es hacia adelante, el cual poseerá un aprendizaje del tipo supervisado, es decir, se le guiará a la red y tendrá como parámetro la salida deseada, además por esto el peso sináptico no es entregado como dato de entrada, se determinan por la red según correlaciones, características de los inputs, entre otros.

Las fases de la red son el entrenamiento de esta y el testeo, la determinación del porcentaje de data para cada uno no es fijo, ya que varía según el modelo que se utilice.

#### 4.3.1.4. Modelos

Los pronósticos son obtenidos por diferentes modelos, para encontrar las mejores configuraciones, número óptimo de pronóstico y variables a considerar.

Se definen 2 modelos principales, los cuales son:

- Modelo para decisión de compra/venta según rentabilidad esperada. Se obtienen dos salidas, la rentabilidad antes del día ex dividend y la rentabilidad después.
- Modelo de decisión de compra/venta según principales indicadores de inversión. Se obtienen 3 salidas, equivalentes a los estadísticos UR, AMR, y AR.

Para ambos casos se desarrollan diferentes configuraciones que se detallan a continuación:

- Entrenamiento de la red de un 85 %: Se considera del total de la data un 85 % para entrenamiento y un 15 % para testeo. Para este caso se realizan 20 pronósticos equivalentes a los outputs de los modelos en base a los 20 primeros dividendos del 2018.
- Entrenamiento de la red de un 80 %: Se considera del total de la data un 80 % para entrenamiento y un 20 % de testeo. De este caso se separan dos casos, el primero es la obtención de los 96 pronósticos, equivalentes al output pronosticado, para los 96 dividendos pagados en el 2017 y 2018. De forma adicional y como segundo caso, se separaran los primeros 47 pronósticos del 2017 para observar su media de forma separada.
- Entrenamiento de la red de un 90 %: Se considera del total de la data un 90 % para entrenamiento y un 10 % para testeo. Igual que en caso anterior, se separa en dos. El primero con los 96 pronósticos para 2017 y 2018 y el segundo caso selecciona los 47 del 2017 para un estudio aparte.

Todo lo mencionado anteriormente se puede resumir en,

**Tabla 4.1:** Resumen modelos. Fuente: Elaboración propia

Modelo	% entrenamiento	Número de pronósticos	Output	
<b>Según Indicadores de inversión</b>	80 %	47, equivalentes a los 57 dividendos pagados en 2017	AMR AR UR	
		96, equivalentes a los 96 dividendos pagados en 2017 y 2018	AMR AR UR	
		85 %	20, equivalentes a los primeros 20 dividendos pagados el 2018	AMR AR UR
	90 %	47, equivalentes a los 57 dividendos pagados en 2017	AMR AR UR	
		96, equivalentes a los 96 dividendos pagados en 2017 y 2018	AMR AR UR	
		<b>Según Rentabilidad</b>	80 %	47, equivalentes a los 57 dividendos pagados en 2017
	96, equivalentes a los 96 dividendos pagados en 2017 y 2018			Rent_antes Rent_después
	85 %		20, equivalentes a los primeros 20 dividendos pagados el 2018	Rent_antes Rent_después
			90 %	47, equivalentes a los 57 dividendos pagados en 2017
96, equivalentes a los 96 dividendos pagados en 2017 y 2018	Rent_antes Rent_después			

Para cada output se realizan 20 pruebas, que se obtienen de las combinaciones capas-neuronas.

Se guardan los pronósticos de todas las pruebas, una vez concluidas estas, se procede a realizar el test de medias, según el estadístico t-student. Para este test se compara la media obtenida en cada prueba, con la media de los datos reales para las fechas pronosticadas. Se realiza la prueba por modelo, tomando todas las combinaciones entre capas y neuronas, se comparan con la media real y en base a esto se escoge cual es la combinación más acertada.

De esta forma se resume cada modelo con sus 5 mejores predicciones, justificado con la diferencia más cercana a cero entre la media de los datos reales y el pronóstico.

### 4.3.2. Modelo Económico: ARIMA

A modo de comparación se realizan modelos económicos en donde la variable pronosticada varía según el modelo que se esté realizando. Como se vio anteriormente, según el caso se pronosticará, rentabilidades: antes y después del día ex dividend, y estadísticos como el UR, AMR y AR. El modelo económico utilizado es ARIMA, el cual involucra componentes auto regresivas, de medias móviles e integración (estacionalidad). Este modelo solo necesita como entrada la variable a pronosticar.

Los modelos son desarrollados con la herramienta Eviews, en la cual se selecciona la serie a pronosticar y se elige la opción de pronóstico ARIMA automático. Considerar que se debe editar la cantidad de observaciones de la serie de trabajo, ajustándola a la cantidad de observaciones de la muestra, más los que se desee pronosticar.

Para comenzar a desarrollar este modelo, se requiere ajustar algunos parámetros, como son el número de integración máxima (usualmente 2), como también el máximo auto regresivo y media móvil.

Luego la herramienta comienza a probar en los distintos modelos que se pueden ir formulando, según combinaciones de las 3 componentes del modelo ARIMA. Sin embargo, es elegido solo un modelo, para este caso se utiliza el criterio Akaike, en donde se elige el menor valor de este estadístico para seleccionar el mejor modelo.

Se debe tener en consideración que para el pronóstico no se utilizan variables externas, solo son componentes temporales de la variable a pronosticar.

Al finalizar las iteraciones, la herramienta entrega el mejor modelo encontrado, las componentes auto regresivas, medias móviles y diferencias óptimos. Además muestra los pronósticos obtenidos

con dicho modelo como una nueva serie.

Los modelos realizados para este caso son en base a las variables:

1. Modelo para decisión de compra/venta según rentabilidad esperada. Se calcula rentabilidad esperada antes y después del día ex dividend, se realizan pronósticos para 20 dividendos del año 2018, 47 dividendos del año 2017 y 96 dividendos considerando 2017 y 2018.
2. Modelo de decisión de compra/venta según principales indicadores de inversión.

Se obtiene rentabilidad esperada antes y después del día ex dividend, UR, AMR y AR.

Se realizan pronósticos para los 20 primeros dividendos del año 2018, 47 dividendos del año 2017 y 96 dividendos considerando 2017 y 2018.

#### 4.4. Mejor modelo: Comparación estadística

Luego de realizar todos los modelos para el pronóstico de los diferentes indicadores que ayudan al inversor a decidir el mejor momento de inversión, se debe elegir que metodología fue más certera.

Primero se elige el mejor modelo de los obtenidos con redes neuronales, esto como se comentó anteriormente se realiza mediante test de media, con la herramienta XLSTAT, aplicando el estadístico t-student. Para esto se compara cada una de las configuraciones realizadas en el modelo (combinaciones entre capas y neuronas) con los datos reales. Este test calcula la diferencia entre las medias de ambas series, con cierto porcentaje de confianza, fijado inicialmente, para las pruebas realizadas en este estudio se utilizó un 95 %, lo que da un valor-p de un 5 %.

Una vez realizadas las pruebas para todas las combinaciones del modelo, se dejan las que aceptaban la hipótesis nula con la que trabaja esta prueba (la diferencia entre las medias de las series evaluadas es igual a 0), esto viendo en cuales el valor-p es mayor a 0.005.

Teniendo las configuraciones aceptadas, se ordenan según la diferencia obtenida de medias, de menor a mayor, y se selecciona como mejor modelo la que tuvo el valor más cercano a 0.

Posteriormente, se realiza el test de media para los resultados obtenidos con el modelo econométrico ARIMA, comparando las medias de estos modelos con la media de los datos reales.

Finalmente, se compara la diferencia entre medias del mejor ARIMA, con la diferencia de

medias de la mejor configuración en RNA. La menor diferencia representa el mejor modelo, debido a su cercanía con los valores reales de la serie.



## 5 Resultados

En base a la metodología señalada anteriormente se presentan los resultados para el efecto ex - dividend en Chile, y los modelos que ayudan a la decisión de compra/venta de los inversores.

### 5.1. Efecto ex dividend en las acciones Chilenas

Se calcularon los indicadores UR, AMR, AR, Yield,  $P_{cum} - P_{ex}$  y Dividendo. En base a los dividendos pagados cada año a las 33 acciones, se obtuvieron 669 registros para cada uno de los indicadores mencionados. Se agruparon todas las acciones para calcular solo un ratio para cada estadístico. A continuación se muestra un extracto de la tabla generada:

**Tabla 5.1:** Extracto de data de estadísticos. Fuente: Elaboración propia

<b>Acción</b>	<b>UR</b>	<b>Yield</b>	<b>AMR</b>	<b>AR</b>	<b>Dividendo</b>	$P_{cum} - P_{ex}$
<b>ITAU</b>	-323,0360	0,0002	-161,0406	0,0351	0,0012	-0,3894
<b>ITAU</b>	-164,7819	0,0001	205,5263	-0,0138	0,0078	-1,2859
<b>ITAU</b>	15,8839	0,0036	15,3308	-0,0484	0,0154	0,2444
<b>ITAU</b>	7,5400	0,0039	5,8871	-0,0186	0,0183	0,1376
<b>OROBLANCO</b>	-21,1004	0,0031	-14,1534	0,0511	0,0188	-0,3963
<b>OROBLANCO</b>	-32,2914	0,0031	-31,3362	0,1108	0,0218	-0,7041
<b>OROBLANCO</b>	35,4878	0,0074	34,2216	-0,1938	0,0242	0,8588
<b>OROBLANCO</b>	3,5306	0,0099	3,8937	-0,0278	0,0323	0,1141
<b>OROBLANCO</b>	5,0602	0,0156	6,4272	-0,0786	0,0405	0,2047
<b>OROBLANCO</b>	-0,6096	0,0231	-1,3928	0,0559	0,0415	-0,0253
<b>OROBLANCO</b>	0,4065	0,0198	-0,8224	0,0358	0,0564	0,0229
<b>OROBLANCO</b>	4363,7564	0,0000	3313,9684	-0,0297	0,0700	305,6375
<b>OROBLANCO</b>	7,6560	0,0249	8,0289	-0,1469	0,1120	0,8575
<b>OROBLANCO</b>	1,6611	0,0450	0,9256	0,0031	0,1293	0,2147
<b>OROBLANCO</b>	-0,3972	0,0204	0,2258	0,0159	0,1526	-0,0606
<b>OROBLANCO</b>	-1,7162	0,0200	-1,1453	0,0445	0,1631	-0,2800
<b>OROBLANCO</b>	-0,0073	0,0185	-1,2020	0,0407	0,1711	-0,0012
<b>OROBLANCO</b>	0,6402	0,0261	0,6939	0,0079	0,1764	0,1129
<b>OROBLANCO</b>	0,2760	0,0595	1,5641	-0,0330	0,2196	0,0606
<b>OROBLANCO</b>	0,2405	0,0726	0,7932	0,0148	0,2250	0,0541
<b>OROBLANCO</b>	1,2804	0,1022	1,1703	-0,0154	0,2545	0,3259
<b>OROBLANCO</b>	0,3057	0,0406	0,4866	0,0206	0,2597	0,0794
<b>OROBLANCO</b>	0,4193	0,0547	0,9170	0,0044	0,3058	0,1282
<b>MASISA</b>	0,8358	0,0146	-0,2163	0,0175	0,3280	0,2741
<b>MASISA</b>	1,7609	0,0478	1,4789	-0,0211	0,3324	0,5853
<b>MASISA</b>	4,0138	0,0061	-3,4992	0,0269	0,3422	1,3735
<b>MASISA</b>	2,8867	0,0129	2,9164	-0,0239	0,3656	1,0553
<b>MASISA</b>	0,1066	0,0841	0,2885	0,0593	0,3751	0,0400
<b>MASISA</b>	-16,2368	0,0034	-11,9035	0,0471	0,4588	-7,4488
<b>MASISA</b>	-9,2819	0,0032	-10,7100	0,0385	0,4612	-4,2812

La cual muestra 28 observaciones, de las 707 totales. Se aplica estadística descriptiva para

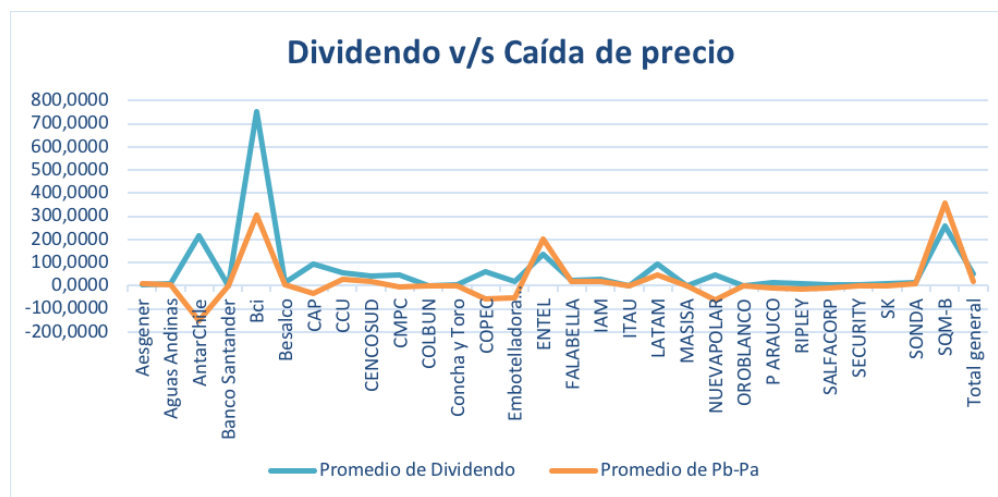
cada una de las series, de lo que se obtiene:

UR		YIELD	
Media	7,3599	Media	0,2165
Error típico	6,2550	Error típico	0,0862
<b>Mediana</b>	0,3735	Mediana	0,0100
Moda	4,9871	Moda	0,0075
Desviación estándar	166,3176	Desviación estándar	2,2916
Varianza de la muestra	27661,5327	Varianza de la muestra	5,2515
Curtosis	669,4491	Curtosis	238,6949
Coefficiente de asimetría	25,5208	Coefficiente de asimetría	14,7331
Rango	4686,7924	Rango	41,8111
Mínimo	-323,0360	Mínimo	0,0000
Máximo	4363,7564	Máximo	41,8112
Suma	5203,4676	Suma	153,0963
Cuenta	707,0000	Cuenta	707,0000
AMR		AR	
Media	7,1700	Media	0,0940
Error típico	4,7780	Error típico	0,0396
Mediana	0,6919	Mediana	0,0035
Moda	1,9201	Moda	-0,0067
Desviación estándar	127,0447	Desviación estándar	1,0523
Varianza de la muestra	16140,3636	Varianza de la muestra	1,1073
Curtosis	652,7167	Curtosis	144,5700
Coefficiente de asimetría	25,0681	Coefficiente de asimetría	11,3206
Rango	3475,0090	Rango	17,8310
Mínimo	-161,0406	Mínimo	-0,9049
Máximo	3313,9684	Máximo	16,9261
Suma	5069,1779	Suma	66,4609
Cuenta	707,0000	Cuenta	707,0000

DIV		$P_{cum} - P_{ex}$	
Media	49,5743	Media	17,5399
Error típico	4,2358	Error típico	10,5203
Mediana	11,9559	Mediana	1,3735
Moda	3,0000	Moda	-130,8500
Desviación estándar	112,6285	Desviación estándar	279,7304
Varianza de la muestra	12685,1726	Varianza de la muestra	78249,1080
Curtosis	32,0967	Curtosis	24,2210
Coefficiente de asimetría	5,0562	Coefficiente de asimetría	-0,2804
Rango	999,9988	Rango	4717,4706
Mínimo	0,0012	Mínimo	-2636,3529
Máximo	1000,0000	Máximo	2081,1176
Suma	35049,0341	Suma	12400,7333
Cuenta	707,0000	Cuenta	707,0000

De la tabla, se puede ver que la media para el dividendo y la caída de precio es muy diferente, si bien es coherente con lo propuesto por Elton y Gruber, quienes confirman que en Chile el precio cae en menor proporción que el dividendo pagado, para esta muestra, es mucho mayor esta diferencia.

Uno de los factores que más altera la muestra, son algunas acciones con comportamientos atípicos, se observa a través del siguiente gráfico, que si bien la mayoría de las acciones tiene una caída de precio similar al pago de sus dividendos, hay otras que alteran mucho la muestra total de mercado.



**Figura 5.1:** Dividendo v/s caída de precio. Fuente: Elaboración propia

Como se muestra, las acciones como AntarChile, BCI, CAP, COPEC Y NuevaPolar, alteran significativamente la muestra de estudio. Por lo que se utilizará la mediana como estadístico de estudio, ya que la muestra contiene datos muy heterogéneos, los que hacen que la media no sea el estadístico más representativo.

A modo de resumen se presentará entonces, la mediana obtenida para cada una de las series.

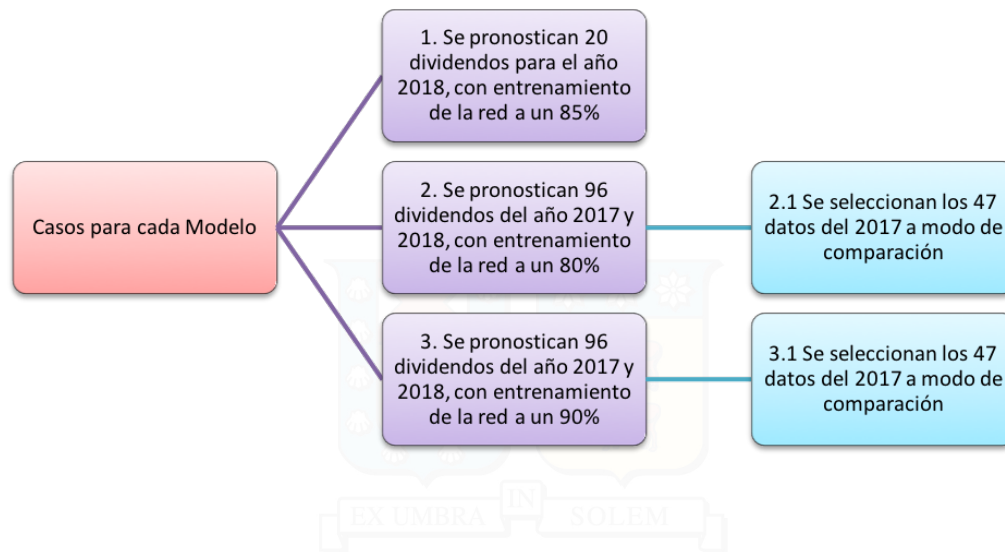
Ratio	Mediana
UR	0,3735
AMR	0,6919
AR	0,0035
YIELD	0,0100
DIV	11,9559
$P_{cum} - P_{ex}$	1,3735

En base a esto se puede concluir que en Chile la caída de precio es menor al dividendo en la fecha de estudio, esto se puede comprobar además por el estadístico UR, el cual representa la caída de precio sobre dividendo, no ajustada, la que indica un valor menor a 1. Esto además deja demostrada la preferencia del inversionista Chileno, el cual indica cierta inclinación por la ganancia de capital ante al pago de dividendo.

## 5.2. Modelos y configuraciones

Se desarrollaron diferentes modelos, determinados por el ratio a pronosticar, según el número de pronósticos y según el porcentaje de entrenamiento y testeo asignado a la red, además los modelos se desarrollan a través de diferentes variables con RNA, o series de tiempo con el modelo econométrico ARIMA.

Para el caso de RNA, se deja el siguiente diagrama para explicar los casos utilizados para cada modelo.



**Figura 5.2:** Casos para modelo 1 y 2. Fuente: Elaboración propia

### 5.2.1. Modelo para decisión de compra/venta según rentabilidad esperada

Para este modelo se pronostica la rentabilidad antes y después del día ex dividend, para luego hacer una comparación con el mejor momento de inversión.

**Caso 1: Pronóstico para primeros 20 dividendos año 2018, entrenamiento 85 % de la data**

De todas las combinaciones capas-neuronas, se muestran las 5 con menor diferencia entre medias, en comparación a la serie de los datos reales.

**Tabla 5.2:** Rentabilidades, entrenamiento 85 %. Fuente: Elaboración propia

Rentabilidad Antes			Rentabilidad Después		
n	c	diferencia	n	c	diferencia
25	8	0,0280	5	8	0,0004
25	4	0,0283	15	8	0,0020
10	4	0,0291	20	8	0,0022
15	8	0,0301	5	6	0,0026
5	4	0,0318	5	4	-0,0030

**Tabla 5.3:** Media rentabilidades antes. Fuente: Elaboración propia

Configuraciones	Real	n=5 c=4	n=10 c=4	n=25 c=4	n=15 c=8	n=25 c=8
<b>Media Rent_antes</b>	0,0537	0,0219	0,0246	0,0254	0,0236	0,0257

**Tabla 5.4:** Media rentabilidades después. Fuente: Elaboración propia

Configuraciones	Real	n=5 c=4	n=15 c=8	n=5 c=8	n=20 c=8	n=5 c=6
<b>Media Rent_después</b>	0,0339	0,0369	0,0319	0,0335	0,0317	0,0313

Obteniendo en ambos casos que la mejor configuración de capas fue 8, pero de neuronas para el caso de rentabilidad antes, fue de 25 y de rentabilidad después de 5.

Además se adjunta la cantidad de configuraciones que aceptaron la hipótesis nula, que las medias entre series es igual a cero, esto para confirmar que el ratio en general fue significativo.

**Tabla 5.5:** Configuraciones que aceptan H0. Fuente: Elaboración propia

Rentabilidad Antes			Rentabilidad Después		
Significancia	Acepta	Rechaza	Significancia	Acepta	Rechaza
5 %	20	0	5 %	18	2
10 %	20	0	10 %	20	0

Al realizar el pronóstico de las 20 primeras rentabilidades antes y después para el 2018, con el modelo econométrico ARIMA, se obtienen los siguientes resultados:

Variable/Modelo	Media ARIMA	Diferencia ARIMA	Diferencia RNA
<b>Rent_antes (3,0,4)</b>	0,038	<b>0,0157</b>	0,0280
<b>Rent_después (3,1,4)</b>	-0,213	0,2475	<b>0,0004</b>

En la tabla se compara además con el mejor modelo obtenido en RNA, de esto se concluye que para la rentabilidad antes, el mejor modelo es el obtenido a través del modelo econométrico y rentabilidad después con redes neuronales.

Considerando los mejores modelos, se obtiene que la rentabilidad antes para el inversor que vende sus acciones será de un 3.8 %, la rentabilidad después será de 3.3 %.

Para los siguientes casos se procede de la misma forma, en donde se presentaran las 5 configuraciones más certeras y los modelos aceptados según la significancia aplicada.

### **Caso 2: Pronóstico para los dividendos 2017 y 2018, entrenamiento 80 % de la data**

Siguiendo la misma línea, se presentan las 5 mejores configuraciones para el modelo en RNA.

**Tabla 5.6:** Rentabilidades, entrenamiento 80 %. Fuente: Elaboración propia

<b>Rentabilidad Antes</b>			<b>Rentabilidad Después</b>		
<b>n</b>	<b>c</b>	<b>diferencia</b>	<b>n</b>	<b>c</b>	<b>diferencia</b>
5	2	0,0110	25	4	-0,0963
20	4	0,0565	20	4	-0,0972
10	6	-0,1063	20	2	0,2523

**Tabla 5.7:** Media rentabilidades antes. Fuente: Elaboración propia

<b>Configuraciones</b>	<b>Real</b>	<b>n=20 c=4</b>
<b>Media Rent_antes</b>	0,0664	0,0100

**Tabla 5.8:** Media rentabilidades después. Fuente: Elaboración propia

<b>Configuraciones</b>	<b>Real</b>	<b>n=5 c=2</b>	<b>n=20 c=2</b>	<b>n=20 c=4</b>	<b>n=25 c=4</b>	<b>n=10 c=6</b>
<b>Media Rent_después</b>	-0,0951	-0,1060	-0,3473	0,0022	0,0012	0,0113

Como se puede observar, para este caso, el modelo de rentabilidad antes, solo tiene una configuración significativa, que sería 4 capas y 20 neuronas. Más abajo se muestra que si la significancia se aumenta a un 10 %, ya pasarían a ser validas 5 configuraciones en vez de 1. Para el modelo de rentabilidad después se tiene que la mejor configuración es con 2 capas y 5 neuronas. Aumentando también en gran cantidad los casos aceptados al pasar de una significancia del 5 % al 10 %.

**Tabla 5.9:** Configuraciones que aceptan H0. Fuente: Elaboración propia

<b>Rentabilidad Antes</b>			<b>Rentabilidad Después</b>		
<b>Significancia</b>	<b>Acepta</b>	<b>Rechaza</b>	<b>Significancia</b>	<b>Acepta</b>	<b>Rechaza</b>
5 %	1	19	5 %	5	15
10 %	5	15	10 %	17	3

Antes de comparar estos resultados con el modelo econométrico, se presentara primero el mismo caso anterior, pero con un entrenamiento de la red de un 90 %, luego se determinará el mejor modelo de estos dos porcentajes de entrenamiento, el cual será comparado con el ARIMA de 96 pronósticos para los años 2017 y 2018.

### **Caso 3: Pronóstico dividendos 2017 y 2018, entrenamiento 90 % de la data**

Considerando también las 5 mejores configuraciones obtenidas para este caso, se obtienen los siguientes resultados:

**Tabla 5.10:** Rentabilidades, entrenamiento 90 %. Fuente: Elaboración propia

<b>Rentabilidad Antes</b>			<b>Rentabilidad Después</b>		
<b>n</b>	<b>c</b>	<b>diferencia</b>	<b>n</b>	<b>c</b>	<b>diferencia</b>
15	8	0,0537	10	2	0,0408
10	8	0,0546	5	2	-0,0581
10	4	0,0547	25	4	-0,0797
5	4	0,0554	20	2	0,0837
25	8	0,0565	25	8	-0,1011

La media para cada una de ellas, se presenta en la siguiente tabla,

**Tabla 5.11:** Media rentabilidades antes. Fuente: Elaboración propia

<b>Configuraciones</b>	<b>Real</b>	<b>n=10 c=8</b>	<b>n=15 c=8</b>	<b>n=25 c=8</b>	<b>n=5 c=4</b>	<b>n=10 c=4</b>
<b>Media Rent_antes</b>	0,0664	0,0118	0,0128	0,0099	0,0111	0,0117

**Tabla 5.12:** Media rentabilidades después. Fuente: Elaboración propia

<b>Configuraciones</b>	<b>Real</b>	<b>n=5 c=2</b>	<b>n=10 c=2</b>	<b>n=20 c=2</b>	<b>n=25 c=4</b>	<b>n=25 c=8</b>
<b>Media Rent_después</b>	-0,0951	-0,0369	-0,1359	-0,1787	-0,0154	0,0061

Además se adjunta la cantidad de configuraciones aceptadas y rechazadas según la significancia dada,

**Tabla 5.13:** Configuraciones que aceptan H0. Fuente: Elaboración propia

<b>Rentabilidad Antes</b>			<b>Rentabilidad Después</b>		
<b>Significancia</b>	<b>Acepta</b>	<b>Rechaza</b>	<b>Significancia</b>	<b>Acepta</b>	<b>Rechaza</b>
5 %	11	9	5 %	11	9
10 %	17	3	10 %	20	0

A modo de comparación con el caso anterior, se puede observar que para un entrenamiento del 90 % de la red, es mayor el número de configuraciones que se acerca a los resultados reales. De esta forma se obtiene el mejor modelo para el pronóstico de rentabilidades, según los 96 dividendos pagados en los años 2017 y 2018,

**Tabla 5.14:** Tabla comparación. Fuente: Elaboración propia

<b>Entrenamiento/diferencias</b>	<b>Rentabilidad antes</b>	<b>Rentabilidad después</b>
90 % entrenamiento	0,0537	0,0408
80 % entrenamiento	0,0565	0,0110

Al considerar que la diferencia entre los mejores modelos no difiere tanto en ambos casos (80 % y 90 % de entrenamiento), se escoge como mejor modelo de pronóstico el obtenido con un 90 % de entrenamiento de la red, esto porque la cantidad de configuraciones en las cuales la diferencia de medias es cercana a 0, son mucho mayor para este caso, que para el entrenamiento de un 80 %, en el cual para la rentabilidad antes solo tiene una configuración aceptada al 5 % de significancia.

Ya determinada la mejor configuración con su mejor nivel de entrenamiento para la red, se compran estos resultados con los obtenidos por el modelo ARIMA, para los 96 pronósticos del 2017 y 2018.

<b>Variable/Modelo</b>	<b>Media ARIMA</b>	<b>Diferencia ARIMA</b>	<b>Diferencia RNA</b>
<b>Rent_antes (3,1,3)</b>	0,0550	<b>0,0110</b>	0,0537
<b>Rent_después (4,1,4)</b>	0,0005	-0,0956	<b>0,0408</b>

De lo anterior se concluye que el mejor modelo para la rentabilidad antes viene dada por el modelo econométrico ARIMA, en cambio para la rentabilidad después viene dado por el modelo en RNA con una configuración de 2 capas y 10 neuronas.

Para el inversor, con la configuración anterior, tiene que si vende sus acciones antes del día ex dividend, obtiene una rentabilidad del 5.5 %, si las vende después de este día, obtiene una rentabilidad de -13,6 %. Por lo tanto, le conviene vender sus acciones antes según este modelo. Por último se tiene el pronóstico extraído del anterior, donde se comparan solo las rentabilidades obtenidas por los 47 dividendos pagados en el 2017, para los dos casos de entrenamiento de la red, al 80 % y 90 %.

### **Caso 2.1: Pronóstico dividendos 2017, entrenamiento 80 % de la data**

Presentando las mejores configuraciones para este caso se obtienen las siguientes:

**Tabla 5.15:** Rentabilidades, entrenamiento 80 %. Fuente: Elaboración propia

<b>Rentabilidad Antes<sup>1</sup></b>			<b>Rentabilidad Después</b>		
<b>n</b>	<b>c</b>	<b>diferencia</b>	<b>n</b>	<b>c</b>	<b>diferencia</b>
20	2	0,0310	20	2	0,0310
5	2	-0,0404	5	2	-0,0404
20	4	0,0680	15	2	0,1686
			20	4	-0,1825

La media para estas configuraciones es:

**Tabla 5.16:** Media rentabilidades antes. Fuente: Elaboración propia

<b>Configuraciones</b>	<b>Real</b>	<b>n=20 c=4</b>
<b>Media Rent_antes</b>	0,0856	0,0176

<sup>1</sup>Considerar que para el caso de la rentabilidad antes, no se obtiene ninguna configuración aceptada al 5 % de significancia, por lo que la configuración de la tabla, hace mención a una obtenida con un 4,7 % de significancia, solo para comparación futura con el modelo ARIMA.

**Tabla 5.17:** Media rentabilidades después. Fuente: Elaboración propia

Configuraciones	Real	n=5 c=2	n=15 c=2	n=20 c=2	n=20 c=4
Media Rent_después	-0,1989	-0,1585	-0,3675	-0,2299	-0,0164

Según la significancia deseada, se obtienen las configuraciones aceptadas en cada caso:

**Tabla 5.18:** Configuraciones que aceptan H0. Fuente: Elaboración propia

Rentabilidad Antes			Rentabilidad Después		
Significancia	Acepta	Rechaza	Significancia	Acepta	Rechaza
5 %	0	20	5 %	4	16
10 %	15	5	10 %	19	1

Para este modelo, se ve que varía mucho la cantidad de configuraciones aceptadas, dando una holgura mayor al nivel de confianza asignado para la prueba. Por ejemplo, para el caso de la rentabilidad antes, se pasa de 0 configuraciones aceptadas a 15, aumentando en un 5 % la significancia en las pruebas.

### Caso 3.1: Pronóstico dividendos 2017, entrenamiento 90 % de la data.

De la misma forma que en el pronóstico de 96 rentabilidades, se comparará primero con la misma data pero para los diferentes porcentajes de entrenamiento, luego de obtener el mejor modelo, se compara con el ARIMA resultante de este pronóstico. Para este caso, las mejores 5 configuraciones son:

**Tabla 5.19:** Rentabilidades, entrenamiento 90 %. Fuente: Elaboración propia

Rentabilidad Antes			Rentabilidad Después		
n	c	diferencia	n	c	diferencia
10	2	0,0713	10	2	-0,0122
20	8	-1,3631	25	2	0,1179
10	2		20	4	-0,1920
			10	6	-0,1981
			20	2	-0,2067

Con sus respectivas medias:

**Tabla 5.20:** Media rentabilidades antes. Fuente: Elaboración propia

<b>Configuraciones</b>	<b>Real</b>	<b>n=10 c=2</b>	<b>n=20 c=8</b>
<b>Media Rent_antes</b>	0,0856	1,4487	0,0143

**Tabla 5.21:** Media rentabilidades después. Fuente: Elaboración propia

<b>Configuraciones</b>	<b>Real</b>	<b>n=10 c=2</b>	<b>n=20 c=2</b>	<b>n=25 c=2</b>	<b>n=20 c=4</b>	<b>n=10 c=6</b>
<b>Media Rent_después</b>	-0,1989	-0,1867	0,0078	-0,3168	-0,0069	-0,0008

Se observa que para la rentabilidad antes, solo hay dos configuraciones aceptadas a un nivel de confianza del 95 %, se deja la cantidad de configuraciones aceptadas según la significancia asignada:

**Tabla 5.22:** Configuraciones que aceptan H0. Fuente: Elaboración propia

<b>Rentabilidad Antes</b>			<b>Rentabilidad Después</b>		
<b>Significancia</b>	<b>Acepta</b>	<b>Rechaza</b>	<b>Significancia</b>	<b>Acepta</b>	<b>Rechaza</b>
5 %	2	18	5 %	9	11
10 %	16	4	10 %	20	0

Ya habiendo presentado los dos modelos para las 47 rentabilidades del 2017, se procede a determinar que porcentaje de entrenamiento es el que refleja un mejor modelo, más acertado a la realidad.

**Tabla 5.23:** Tabla comparación. Fuente: Elaboración propia

<b>Entrenamiento/diferencias</b>	<b>Rentabilidad antes</b>	<b>Rentabilidad después</b>
90 % entrenamiento	0,0713	<b>-0,0122</b>
80 % entrenamiento	<b>0,0680</b>	0,0310

Al igual que en los modelos anteriores, para la rentabilidad antes, la mejor opción vienen dado con el entrenamiento de la red a un 80 %. Sin embargo, se determina dejar como mejor modelo en ambos casos, a los obtenidos con un porcentaje de la red a un 90 %, esto principalmente porque para el modelo de rentabilidad antes a un porcentaje de entrenamiento de 80 % de la red, no se obtuvo ninguna configuración significativa con un 5 % de significancia.

Teniendo esto, se compara con el modelo ARIMA para el pronóstico de las 47 rentabilidades.

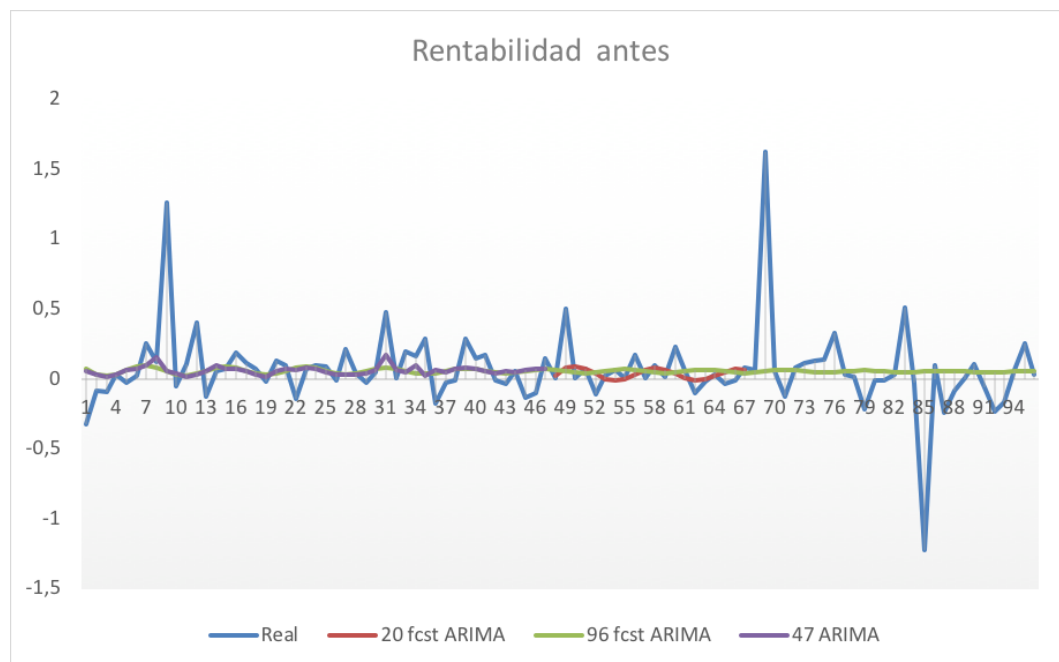
Variable/Modelo	Media ARIMA	Diferencia ARIMA	Diferencia RNA
<b>Rent_antes (2,0,4)</b>	0,0593	<b>0,0263</b>	0,0713
<b>Rent_después (3,1,4)</b>	-0,0038	-0,1950	<b>-0,0122</b>

En donde se determina que para el modelo de rentabilidad antes, el mejor modelo viene dado por el ARIMA, en cambio para la rentabilidad después viene dado por el modelo de RNA.

Según este modelo, y siguiendo la coherencia de todos los obtenidos anteriormente, se le recomienda al inversor vender sus acciones antes del día ex dividendo, esto debido a que la rentabilidad antes obtenida por el mejor modelo es de 5.9 %, en cambio la rentabilidad después es de -18.6 %.

En base a todos los modelos presentados anteriormente, se puede seleccionar el mejor modelo para los casos de 20, 96 y 47 forecast.

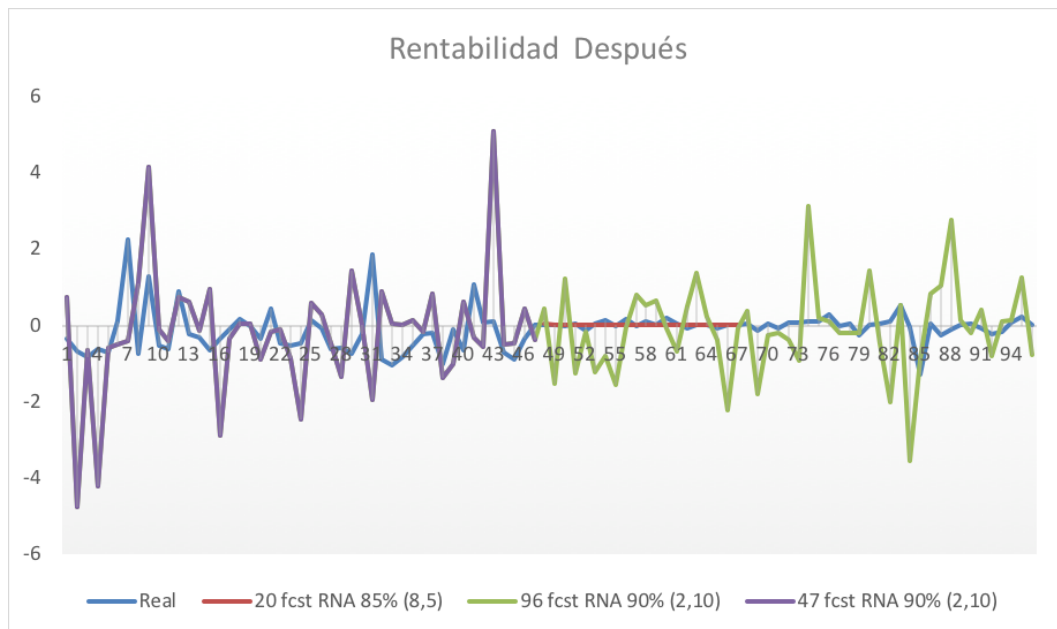
Para el modelo de rentabilidad antes, se obtiene que el mejor modelo para todos los casos es el obtenido por ARIMA.



**Figura 5.3:** Mejores modelos rentabilidad antes. Fuente: Elaboración propia

Para el modelo de rentabilidad después se tiene que para todos los forecast realizados, la mejor

opción es la obtenida con RNA, sin embargo varía el porcentaje de entrenamiento utilizado y la configuración elegida.



**Figura 5.4:** Mejores modelos rentabilidad después. Fuente: Elaboración propia

En los gráficos se pueden observar las mejores configuraciones para las rentabilidades, siendo el paréntesis la referencia a (capas, neuronas) seleccionada como mejor configuración

### 5.2.2. Modelo para decisión de compra/venta según principales indicadores de inversión

**Caso 1: Pronóstico para primeros 20 dividendos año 2018, entrenamiento 85 % de la data.**

Se muestran los 5 mejores configuraciones para todos los estadísticos a pronosticar, UR, AMR y de forma complementaria a los dos anteriores, AR.

**Tabla 5.24:** Estadísticos, entrenamiento 85 %. Fuente: Elaboración propia

UR			AMR			AR		
n	c	diferencia	n	c	diferencia	n	c	diferencia
20	8	-0,0187	20	4	-0,3883	25	4	-0,0314
25	8	-0,2104	5	6	0,6040	25	6	-0,2366
15	6	-0,6213	15	8	0,6077	10	2	-2,9450
5	4	-0,6588	25	8	0,7320	5	2	6,0403
10	8	-0,7042	15	4	0,7393			

La media para cada caso es:

**Tabla 5.25:** Media UR. Fuente: Elaboración propia

Configuraciones	Real	n=20 c=8	n=25 c=8	n=10 c=8	n=15 c=6	n=5 c=4
Media UR	5,6036	5,6223	5,8140	6,3078	6,2250	6,2624

**Tabla 5.26:** Media AMR. Fuente: Elaboración propia

Configuraciones	Real	n=15 c=4	n=20 c=4	n=25 c=8	n=15 c=8	n=5 c=6
Media AMR	5,5426	4,8034	5,9309	4,8106	4,9349	4,9386

**Tabla 5.27:** Media AR. Fuente: Elaboración propia

Configuraciones	Real	n=5 c=2	n=10 c=2	n=25 c=4	n=25 c=6
Media AR	-0,0228	-6,0631	2,9222	0,0087	0,2139

Como en los casos anteriores, se adjunta la cantidad de configuraciones que fueron aceptadas con variaciones en el porcentaje de la significancia, para determinar si el modelo fue o no válido.

**Tabla 5.28:** Configuraciones que aceptan H0. Fuente: Elaboración propia

UR			AMR		
Significancia	Acepta	Rechaza	Significancia	Acepta	Rechaza
5 %	19	1	5 %	20	0
10 %	20	0	10 %	20	0

<b>AR</b>		
<b>Significancia</b>	<b>Acepta</b>	<b>Rechaza</b>
5 %	4	16
10 %	7	13

Se observa que el único modelo que no es representativo es el AR, ya que son muy pocas las configuraciones que se acercan a los datos reales, con una significancia del 10 % solo se aceptan 7 configuraciones de 20. Esto se repite en la mayoría de los modelos, por lo que se procede a comparar más exhaustivamente solo los modelos UR y AMR.

Se compara estos resultados con el modelo ARIMA, para determinar cual arroja pronósticos más certeros, se tiene:

<b>Variable/Modelo</b>	<b>Media ARIMA</b>	<b>Diferencia ARIMA</b>	<b>Diferencia RNA</b>
<b>UR(2,0,2)</b>	2,2812	3,3224	<b>0,0187</b>
<b>AMR(2,0,3)</b>	4,8901	0,7127	<b>0,3883</b>
<b>AR(0,0,3)</b>	0,0880	-0,1108	<b>0,0314</b>

En base a las diferencias mostradas anteriormente, se determina que para todos los casos el mejor modelo viene dado por el realizado con RNA.

La media que obtiene cada estadístico según su mejor opción es:

**Tabla 5.29:** Media de cada estadístico según mejor opción

<b>Variable</b>	<b>UR</b>	<b>AMR</b>	<b>AR</b>
Media	5,6223	5,9309	0,0087

Sobre estos resultados se concluirá cuando se determine el mejor para cada modelo.

### **Caso 2: Pronóstico dividendos 2017 y 2018, entrenamiento 80 % de la data.**

Las mejores configuraciones para este modelo son:

**Tabla 5.30:** Estadísticos, entrenamiento 85 %. Fuente: Elaboración propia

UR			AMR		
n	c	diferencia	n	c	diferencia
15	6	-1,9555	25	8	0,0240
25	4	-2,1098	15	6	-0,0743
25	8	-2,1230	25	6	-0,1591
25	6	-2,2857	10	4	-0,2146
20	8	-2,3565	20	8	-0,3259

Como se puede ver en las tablas anteriores, solo se presenta el estadístico UR y AMR, ya que AR no tuvo configuraciones significativas (ni cercanas), con ninguna de las dos significancias probadas.

Las medias de los estadísticos presentados anteriormente son:

**Tabla 5.31:** Media UR. Fuente: Elaboración propia

Configuraciones	Real	n=25 c=4	n=15 c=6	n=25 c=6	n=20 c=8	n=25 c=8
Media UR	-0,0770	2,0328	1,8784	2,2087	2,2794	2,0459

**Tabla 5.32:** Media AMR. Fuente: Elaboración propia

Configuraciones	Real	n=20 c=8	n=25 c=8	n=15 c=6	n=25 c=6	n=10 c=4
Media AMR	2,0126	2,3386	1,9887	2,0869	2,1717	2,2273

La cantidad de configuraciones aceptadas por significancia son las siguientes:

**Tabla 5.33:** Configuraciones que aceptan H0. Fuente: Elaboración propia

Significancia	UR		Significancia	AMR	
	Acepta	Rechaza		Acepta	Rechaza
5 %	16	4	5 %	18	2
10 %	18	2	10 %	18	2

### Caso 3: Pronóstico dividendos 2017 y 2018, entrenamiento 90 % de la data.

Para comparar que porcentaje de entrenamiento es el óptimo, se realiza la misma cantidad de pronósticos, 96 estadísticos para cada serie, pero con un entrenamiento del 90 % de la data. Para este caso las mejores configuraciones son las siguientes:

**Tabla 5.34:** Estadísticos, entrenamiento 90 %. Fuente: Elaboración propia

UR			AMR		
n	c	diferencia	n	c	diferencia
10	2	-0,5192	20	4	-0,1501
25	8	-2,5698	25	8	-0,2989
10	8	-2,8390	25	4	-0,4809
20	6	-3,5438	20	8	-0,6167
5	6	-3,5664	5	6	-0,7099

Igual que el caso anterior, no es considerado el ratio AR. La media para estas configuraciones es la siguiente:

**Tabla 5.35:** Media UR. Fuente: Elaboración propia

Configuraciones	Real	n=5 c=6	n=20 c=6	n=25 c=8	n=10 c=8	n=10 c=2
Media UR	-0,0770	3,4894	3,4668	2,4928	2,7620	0,4422

**Tabla 5.36:** Media AMR. Fuente: Elaboración propia

Configuraciones	Real	n=20 c=4	n=25 c=4	n=20 c=8	n=25 c=8	n=5 c=6
Media AMR	2,0126	2,1627	2,4935	2,6293	2,3115	2,7225

Y la significancia para este modelo es:

**Tabla 5.37:** Configuraciones que aceptan H0. Fuente: Elaboración propia

Significancia	UR		Significancia	AMR	
	Acepta	Rechaza		Acepta	Rechaza
5 %	20	0	5 %	19	1
10 %	20	0	10 %	20	0

Para definir que porcentaje de entrenamiento es mejor para el pronóstico de los estadísticos para 2017 y 2018, se compara la diferencia entre medias, de los mejores modelos obtenidos para cada caso:

**Tabla 5.38:** Tabla comparación. Fuente: Elaboración propia

<b>Entrenamiento/diferencias</b>	<b>UR</b>	<b>AMR</b>
90 % entrenamiento	<b>-0,5192</b>	-0,1501
80 % entrenamiento	-1,9555	<b>0,0240</b>

Con esto se determina que para ambos modelos por cantidad de configuraciones aceptadas según significancia, la red que obtuvo 90 % de la data en entrenamiento, aseguró más combinaciones aceptadas. Sin embargo, diferencia con la data de 80 % de entrenamiento, para este caso fue mínima. Por lo que se decide considerar como mejor modelo para el estadístico UR, el obtenido de la data con 90 % de entrenamiento, y el estadístico AMR, con la data obtenida al entrenar la red a un 80 % de la data.

Teniendo los mejores modelos obtenidos con RNA, para los pronósticos de 2017 y 2018, se comparan con el modelo econométrico ARIMA. De esta forma se concluye cual modelo representa de mejor forma la serie pronosticada:

<b>Variable/Modelo</b>	<b>Media ARIMA</b>	<b>Diferencia ARIMA</b>	<b>Diferencia RNA</b>
<b>UR(4,0,4)</b>	0,0593	-2,7928	<b>-0,5192</b>
<b>AMR(0,0,0)</b>	-0,0038	-1,2967	<b>0,0240</b>

Con lo que se concluye que para los dos estadísticos el mejor modelo es obtenido con RNA, con sus respectivas configuraciones.

La media para cada uno de estos estadísticos es:

**Tabla 5.39:** Medias de cada estadístico. Fuente: Elaboración propia

<b>Variable</b>	<b>UR</b>	<b>AMR</b>
Media	0,4422	1,9887

### **Caso 2.1: Pronóstico dividendos 2017, entrenamiento 80 % de la data.**

Estos últimos dos casos son la extracción de los datos del 2017 de la data anterior, esto a modo de comparación.

Se muestran las mejores configuraciones para este caso:

**Tabla 5.40:** Estadísticos, entrenamiento 80 %. Fuente: Elaboración propia

UR			AMR		
n	c	diferencia	n	c	diferencia
25	8	-5,8780	15	6	0,3037
15	6	-5,8983	25	6	-0,7620
15	8	-6,0579	20	8	-0,8645
20	4	-6,1380	25	8	-1,5092
20	8	-6,1723	15	8	-1,5496

Como en todos los casos anteriores (y el que sigue) el indicador AR no es considerado por su poca representatividad para la serie.

La media que representa a cada una de las configuraciones anteriores es:

**Tabla 5.41:** Media UR. Fuente: Elaboración propia

Configuraciones	Real	n=15 c=8	n=20 c=8	n=25 c=8	n=20 c=4	n=15 c=6
Media UR	-3,8221	2,2358	2,3502	2,0559	2,3159	2,0763

**Tabla 5.42:** Media AMR. Fuente: Elaboración propia

Configuraciones	Real	n=15 c=8	n=20 c=8	n=25 c=8	n=15 c=6	n=25 c=6
Media AMR	0,9083	2,4580	1,7729	2,4176	0,6047	1,6703

Y las configuraciones aceptadas según significancia son las siguientes cantidades:

**Tabla 5.43:** Configuraciones que aceptan H0. Fuente: Elaboración propia

Significancia	UR		Significancia	AMR	
	Acepta	Rechaza		Acepta	Rechaza
5 %	18	2	5 %	17	3
10 %	19	1	10 %	18	2

Para poder comparar que porcentaje de entrenamiento es el más adecuado para este caso, se compara este modelo con la misma cantidad de pronósticos, pero con un entrenamiento de la data del 90 %.

### Caso 3.1: Pronóstico dividendos 2017, entrenamiento 90 % de la data.

Para este último caso de comparación, se presentan las mejores configuraciones obtenidas con RNA.

**Tabla 5.44:** Estadísticos, entrenamiento 80 %. Fuente: Elaboración propia

UR			AMR		
n	c	diferencia	n	c	diferencia
10	2	0,5076	25	8	-0,6405
20	6	-5,9261	20	8	-1,3170
25	8	-5,9928	25	4	-1,6536
15	4	-6,7511	5	8	-1,7596
10	8	-6,8899	10	8	-1,8865

Las medias para cada una de las configuraciones anteriores, se detallan a continuación.

**Tabla 5.45:** Media UR. Fuente: Elaboración propia

Configuraciones	Real	n=10 c=2	n=15 c=4	n=20 c=6	n=10 c=8	n=25 c=8
Media UR	-3,8221	-4,3297	2,9290	2,1040	3,0678	2,1707

**Tabla 5.46:** Media AMR. Fuente: Elaboración propia

Configuraciones	Real	n=25 c=4	n=5 c=8	n=10 c=8	n=20 c=8	n=25 c=8
Media AMR	0,9083	2,5620	2,6680	2,7948	2,2253	1,5489

Y las configuraciones según la significancia elegida, se detallan como:

**Tabla 5.47:** Configuraciones que aceptan H0. Fuente: Elaboración propia

UR			AMR		
Significancia	Acepta	Rechaza	Significancia	Acepta	Rechaza
5 %	20	0	5 %	20	0
10 %	20	0	10 %	20	0

Eligiendo la mejor opción según el entrenamiento de la data elegida, se tiene que:

**Tabla 5.48:** Tabla comparación. Fuente: Elaboración propia

Entrenamiento/diferencias	UR	AMR
90 % entrenamiento	<b>0,5076</b>	-0,6405
80 % entrenamiento	-5,8780	<b>0,3037</b>

En donde al igual que para los pronósticos de 2017 y 2018, se elige como mejor modelo para el estadístico UR, el que entrena con un 90 % de la data, y para el estadístico AMR, el modelo con entrenamiento de 80 %, sin embargo, el AMR tiene mayor cantidad de configuraciones cercanas a la serie real en el modelo con entrenamiento 90 %, por lo que no sería malo considerar también para este estadístico, que el mejor modelo sea obtenido con este último nivel de entrenamiento.

Con estos modelos, se compara el modelo econométrico ARIMA:

Variable/Modelo	Media ARIMA	Diferencia ARIMA	Diferencia RNA
<b>UR(2,0,2)</b>	2,5409	-6,3630	<b>0,5076</b>
<b>AMR(0,0,0)</b>	3,3320	-2,4237	<b>0,3037</b>

De lo cual se puede ver que para todos los casos, el mejor modelo queda determinada por las mejores configuraciones obtenidas con RNA.

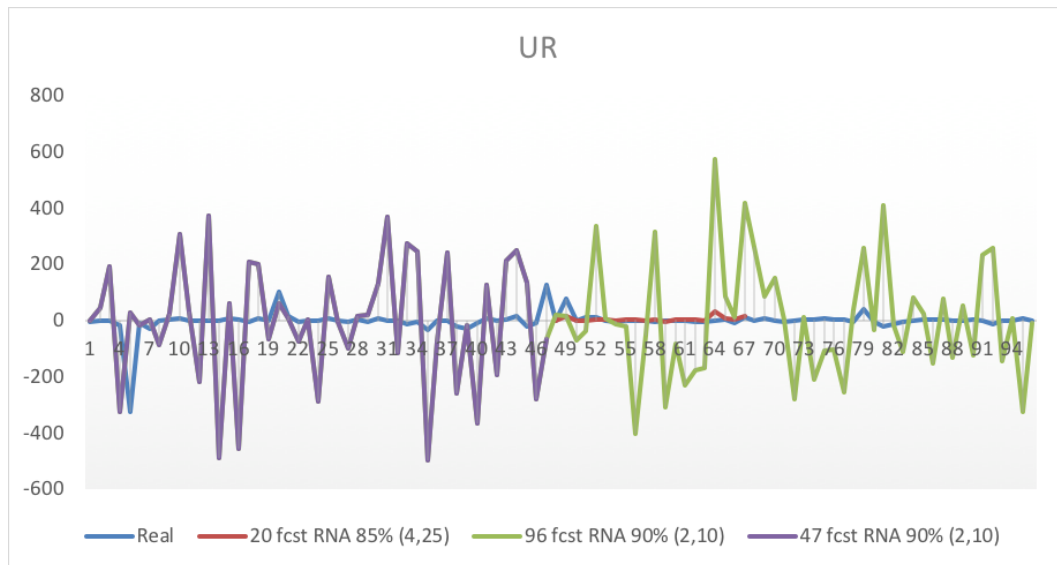
Las medias de estos modelos son las siguientes:

**Tabla 5.49:** Medias de cada estadístico. Fuente: Elaboración propia

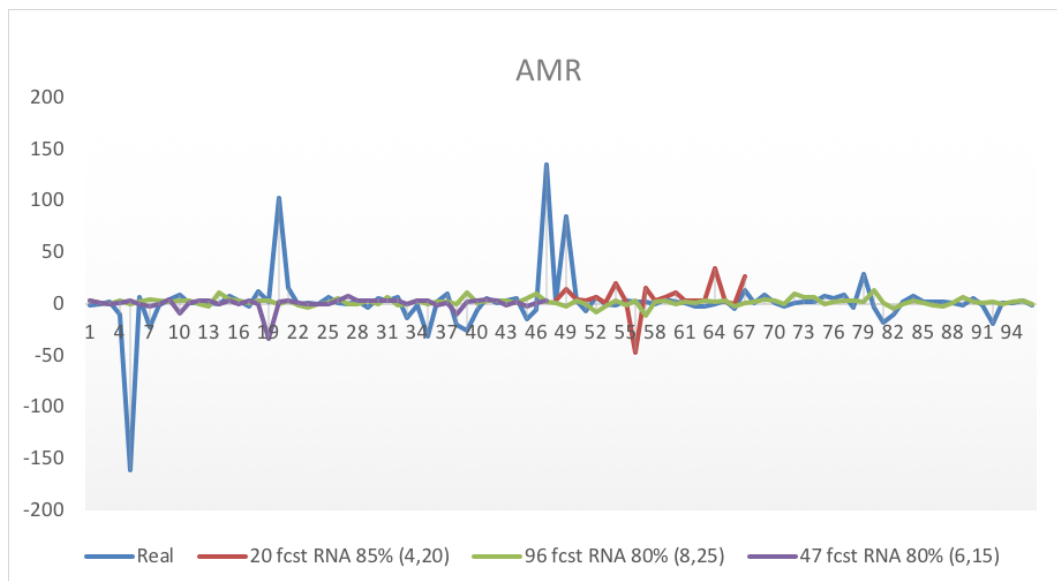
Variable	UR	AMR
Media	-4,3297	0,6047

Teniendo en cuenta todos los casos presentados para los estadísticos UR, AMR y AR, se concluye en base a los mejores modelos para UR y AMR, descartando como modelo significativo para estudio el obtenido con AR, por los motivos mencionados anteriormente.

A continuación se presentan los gráficos para las series UR y AMR, obtenidos con los mejores modelos, de las series con 20, 47 y 96 forecasting.



**Figura 5.5:** Mejores modelos UR. Fuente: Elaboración propia



**Figura 5.6:** Mejores modelos AMR. Fuente: Elaboración propia

Ya presentados todos los resultados, para los modelos de rentabilidad del inversor, y estadísticos importantes. Se presenta una tabla resumen en donde se explica el procedimiento y los mejores

modelos.

En el modelo de rentabilidad, los mejores modelos para todas las opciones de entrenamiento son, en el caso de rentabilidad antes, el modelo econométrico ARIMA, y para rentabilidad después los realizados con RNA. Para los modelos de los principales estadísticos, todos concluyen con el mejor modelo, el obtenido en RNA, pero varían el porcentaje de entrenamiento que seleccionan para cada opción.

A continuación se presenta una tabla resumen con los mejores modelos obtenidos para cada caso.

**Tabla 5.50:** Resumen mejores modelos por caso. Fuente: Elaboración propia

<b>MEJOR MODELO</b>	<b>20 FCST 2018</b>	<b>96 FCST 2017-2018</b>	<b>47 FCST 2017</b>
<b>RENT ANTES</b>	ARIMA	ARIMA	ARIMA
<b>RENT DESPUÉS</b>	RNA 85 % (8,5)	RNA 90 % (2,10)	RNA 90 % (2,10)
<b>UR</b>	RNA 85 % (4,25)	RNA 90 % (2,10)	RNA 90 % (2,10)
<b>AMR</b>	RNA 85 % (4,20)	RNA 80 % (8,25)	RNA 80 % (6,15)
<b>AR</b>	RNA 85 % (4,25)	-	-

El paréntesis en cada modelo de RNA, representa las capas, neuronas, de la mejor combinación.

Además se adjunta la cantidad de configuraciones que fueron aceptadas, con los diferentes porcentajes de significancia probados, considerando el mejor entrenamiento según la tabla anterior.

**Tabla 5.51:** Cantidad de configuraciones aceptadas,  $\alpha$  5 %. Fuente: Elaboración propia

<b>SIGNIFICANCIA 5 %</b>	<b>20 FCST 2018</b>	<b>96 FCST 2017-2018</b>	<b>47 FCST 2017</b>
<b>RENT ANTES</b>	20	11	2
<b>RENT DESPUÉS</b>	18	11	9
<b>UR</b>	19	20	20
<b>AMR</b>	20	18	17
<b>AR</b>	4	0	0

**Tabla 5.52:** Cantidad de configuraciones aceptadas,  $\alpha$  10 %. Fuente: Elaboración propia

<b>SIGNIFICANCIA 10 %</b>	<b>20 FCST 2018</b>	<b>96 FCST 2017-2018</b>	<b>47 FCST 2017</b>
<b>RENT ANTES</b>	20	17	16
<b>RENT DESPUÉS</b>	20	20	20
<b>UR</b>	20	20	20
<b>AMR</b>	20	18	18
<b>AR</b>	7	0	5

Para finalizar se resumen los resultados para la hipótesis del test de medias, que señala que la diferencia entre las medias de las dos series evaluadas debe ser igual a cero, por lo que se adjunta la diferencia obtenida en cada “mejor modelo” y la media que representa dicha serie.

**Tabla 5.53:** Resumen diferencias entre las medias de las series. Fuente: Elaboración propia

<b>DIFERENCIAS</b>	<b>20 FCST 2018</b>	<b>96 FCST 2017-2018</b>	<b>47 FCST 2017</b>
<b>RENT ANTES</b>	0,0157	0,011	0,0263
<b>RENT DESPUÉS</b>	0,0004	0,0408	-0,0122
<b>UR</b>	0,0187	-0,5192	0,5076
<b>AMR</b>	0,3883	0,024	0,3037
<b>AR</b>	0,0314	-	-

**Tabla 5.54:** Medias-Medianas de las series. Fuente: Elaboración propia

<b>MEDIAS-MEDIANAS</b>	<b>20 FCST 2018</b>	<b>Real 20 datos</b>	<b>96 FCST 2017-2018</b>	<b>Real 96 datos</b>
<b>RENT ANTES</b>	0,038	0,0537	0,055	0,0664
<b>RENT DESPUÉS</b>	0,0335	0,0339	-0,1359	-0,0951
<b>UR</b>	3,4281	5,6036	4,8260	0,6684
<b>AMR</b>	3,2657	5,5426	2,2628	1,4627
<b>AR</b>	0,0348	-0,0228	-	-

**Tabla 5.55:** Medias-Medianas de las series. Fuente: Elaboración propia

<b>MEDIAS-MEDIANAS</b>	<b>47 FCST 2017</b>	<b>Real 47 datos</b>
<b>RENT ANTES</b>	0,0593	0,0856
<b>RENT DESPUÉS</b>	-0,1867	-0,1989
<b>UR</b>	10,7265	0,6684
<b>AMR</b>	1,8914	1,3033
<b>AR</b>	-	-



## 6 Conclusiones y recomendaciones

La inversión en acciones, o en cualquier instrumento de inversión con renta variable, tienen cierto porcentaje de incertidumbre que no puede ser controlada. Esto debido a los múltiples factores (algunos no predecibles) que alteran el valor de venta/compra de las acciones en forma particular, por ejemplo el mayor factor impredecible son las expectativas, que se pueden ver alteradas por cualquier noticia y factor externo que no puede ser visualizado con anterioridad.

Sin embargo, existen componentes que si se pueden conocer con anterioridad y minimizan la incertidumbre al invertir.

En este trabajo se toma como actor principal, al inversionista que desea vender sus acciones, en donde la decisión principal es el momento temporal en el cual debe vender para maximizar su rentabilidad. Estos espacios temporales se dividen en antes de que la acción salga ex dividend y después, ya que es en esta fecha límite en donde el inversionista pierde el derecho a recibir dividendo para la acción que posee.

La primera parte de este trabajo, revela el efecto ex dividend en el mercado chileno, para ello se seleccionan 29 acciones, las cuales son consideradas dentro de las acciones más transadas, al estar dentro del IPSA, que engloba las acciones más líquidas del mercado.

En un mercado perfecto, la caída de precio debiese ser igual que el dividendo pagado, ya que las tasas impositivas no juegan un rol decisivo. Por este motivo el ratio UR, caída de precio sobre dividendo, debiese tender a uno. Sin embargo en el mundo menos perfecto, se observa que estos ratios están afectados a muchas otras variables que hacen más incierto el resultado.

Con las pruebas realizadas por estadística descriptiva se tiene que el precio de la acción en promedio, cae luego del día ex dividend en 1.37 [\$], en cambio el dividendo tiene un pago de 11.96 [\$], considerando las medianas obtenidas para cada serie, debido a que los datos son muy heterogéneo y presentan algunos datos atípicos que podrían ensuciar el resultado si se utilizaba la media como estadístico de comparación.

Como primera observación se tiene que la caída de precio es menor que el pago de dividendo observado para este mercado. Al entrar a analizar la caída de precio sobre dividendo con el ratio UR, se obtiene que la mediana en este caso es de 0.374, lo que es coherente con los resultados anteriores. Eso demuestra que en los años de estudio, 2007 a 2017, el entorno tributario general para los inversionistas ha sido consistente con una preferencia por las ganancias de capital. Las ganancias de capital en general no son gravadas, mientras que los dividendos sí lo son. Este puede ser uno de los grandes motivos para obtener este ratio. Además considerar según el modelo de clientela tributario, el ratio caída de precio sobre dividendo representa las tasas impositivas marginales relativas de los accionistas de las acciones de una empresa, con lo que se puede inferir que esta preferencia por la ganancia de capital es causa de una menor tasa de impuesto a la ganancia de capital que al dividendo.

La segunda parte de este trabajo, entrega el momento óptimo para que el inversor venda sus acciones.

Se realizaron dos modelos principales, uno que se basa en las rentabilidades que podría obtener vendiendo antes y después de la fecha ex dividend, y el segundo trata del pronóstico de los ratios que muestran la caída de precio sobre dividendo, con ajuste y sin ajuste del mercado. Estos dos modelos conversan y entregan la mejor opción de inversión.

Para los modelos, se realizan 3 pronósticos, en el cual se pronosticas los 20 primeros estadísticos para el año 2018, los 96 del año 2017 y 2017 y solo los 47 del año 2017. El mejor modelo para cada uno de los casos se escogió en base a la menor diferencia entre medias, realizada con el estadístico t-student.

Para los 20 pronostico del 2018, solo la rentabilidad antes tiene mejores resultados con el modelo econométrico ARIMA, todos los demás (rentabilidad después, UR, AMR y AR) presentan modelos más ajustados con los obtenidos con RNA. Los porcentajes de entrenamiento óptimo en este caso para todos es un 85 %, solo se prueba esta opción. La configuración para cada serie es:

- Rentabilidad después: 8 capas y 5 neuronas.
- UR: 4 capas y 25 neuronas.
- AMR: 4 capas y 20 neuronas.
- AR: 4 capas y 25 neuronas.

Para los 96 pronósticos del 2017 y 2018, y para los 47 del 2017 la rentabilidad antes tiene mejores resultados con el modelo ARIMA, en cambio todos los demás con RNA. Los porcentajes

de entrenamiento y configuraciones para el modelo de 96 fcst y 47 fcst respectivamente son:

- Rentabilidad después: RNA 90 % entrenamiento, con 2 capas y 10 neuronas, para ambos casos.
- UR: RNA 90 % entrenamiento, con 2 capas y 10 neuronas, para ambos casos.
- AMR: RNA 80 % entrenamiento para ambos casos. 8 casos y 25 neuronas para el primer caso, y 6 capas y 15 neuronas para el segundo.

A modo de ratio y de forma general, se tiene que el mejor modelo según menor diferencia entre medias obtenidas y mayores configuraciones aceptadas con significancias al 5 % y al 10 % son:

- Rentabilidad antes: **Modelo ARIMA con 20 pronósticos para el 2018**. Si bien la diferencias entre medias es menor para el de 96 pronósticos, esta es mínima, y las configuraciones aceptadas para el de 20 pronósticos son todas las realizadas, hasta con 5 % de significancia.
- Rentabilidad después: **Modelo RNA 85 % de entrenamiento con 20 pronósticos para el 2018**. Con la menor diferencia entre medias, y la mayor cantidad de configuraciones aceptadas para ambas significancias.
- UR: **Modelo RNA 85 % de entrenamiento con 20 pronósticos para el 2018**. Tomando en cuenta que la diferencia entre medias es la mínima, con alta diferencia con los otros modelos. Además de una alta aceptación a bajas significancias.
- AMR: Compiten los modelos RNA 85 % de entrenamiento con 20 pronósticos para el 2018, con RNA 80 % de entrenamiento con 96 pronósticos para 2017 y 2018. Ya que, este último tiene la menor diferencia entre medias, la cual es significativamente menor a las obtenidas en los otros modelos. Sin embargo, por configuraciones aceptadas, gana el primer modelo, en donde con una significancia del 5 %, ya acepta todas las pruebas realizadas como válidas. A pesar de esto, se elige como mejor modelo para este ratio el de **RNA 80 % de entrenamiento con 96 pronósticos para 2017 y 2018**, por su baja diferencia entre medias con la serie real.
- AR: **Modelo RNA 85 % de entrenamiento con 20 pronósticos para el 2018**. Sin embargo se opta por no considerarlo como un modelo aceptable, ya que solo para esta prueba se obtienen configuraciones aceptadas, aunque solo 7 de 20, para una significancia del 10 %. Para los otros modelos no se obtienen configuraciones válidas, lo que indica que el modelo no es representativo para la data real. Esto se puede deber principalmente al cálculo del

ratio, ya que al restar el riesgo de mercado, en este estudio se considera el indicador del IPSA como representación de mercado, y puede que algunos datos escapen de lo real.

Para el forecasting de 20 rentabilidades del 2018, se tiene que la rentabilidad obtenida antes es de un 3.8 %, y la rentabilidad después de un 3.3 %, lo que lleva al inversor a vender sus acciones antes que salga ex dividend para mayor rentabilidad. Esto es apoyado por el modelo UR que da una mediana de 3.43, y por el mismo ratio pero ajustado por el mercado, AMR, con una mediana de 3.27, lo que explica un bajo dividendo en comparación a la caída de precio, lo que apoya la decisión de vender antes. Comparando lo obtenido en los modelos con la data real, tiene completa relación, ya que los primeros 20 estadísticos arrojan que el inversor obtiene mayor rentabilidad al vender las acciones antes, según la data registrada.

Para el modelo con 96 forecast correspondiente a 2017 y 2018, se tiene que según modelo de rentabilidades, al inversor le conviene vender antes sus acciones antes, apoyando lo obtenido anteriormente. Con una rentabilidad antes del 5.5 % y rentabilidad después de un -13.6 %, apoyando este resultado, el estadístico UR tiene una mediana de 4.83 y AMR de 2.26, coherente con la data real, que indica una preferencia a venta antes del día ex dividend, salvo el estadístico UR que arroja un valor menor a uno, que se debe principalmente por los datos atípicos de la data en estudio. Sin embargo al ajustar el estadístico por el mercado, el ratio AMR, si es mayor a 1, lo que es coherente con los resultados anteriores.

Por último se tiene la data de 47 forecast, que representa un extracto de la data de 96 forecast, considerando solo el año 2017, para tener una visión más a corto plazo. Estos resultados, para ambos modelos, son consecuentes con los obtenidos anteriormente, y también sugieren una venta de las acciones antes que salga ex dividend, con una rentabilidad antes de 5.9 % y una rentabilidad después de -18.7 %, con una caída de precio sobre dividendo de 10.73, y ajustada de 1.89. Este caso, al ser un extracto del anterior, tiene la misma anomalía en la data real, donde el estadístico UR da una mediana menor a 1, la cual es rebatida con el ratio ajustado que muestra una mediana mayor a una, que es coherente con los resultados encontrados para el caso.

En conclusión con este trabajo se observa la preferencia del inversor por los dividendos, para los años 2017 y 2018, lo cual es contrario a la preferencia encontrada al tomar la data del 2007 al 2017 para comprobación de efecto ex dividend en Chile.

Esta preferencia encontrada en los resultados, por los dividendos ante la ganancia de capital, se puede ver sesgada por la ley 18.046, artículo 79, en donde se obliga a las sociedades anónimas abiertas a pagar como mínimo el 30 % de sus ganancias, como dividendos en efectivo, lo que

direcciona al inversor a esta preferencia.



# Bibliografía

- E. T. Arroyave C and D. A. Agudelo R. Rendimiento ex-dividendo como indicador de eficiencia en un mercado emergente: caso colombiano 1999-2007. *Journal of Economics, Finance and Administrative Science*, 17(33):38–47, 2012.
- Bolsa Comercio Santiago. IPSA, 2016.
- A. Castillo and K. Jakob. The Chilean ex-dividend day. *Global Finance Journal*, 17(1):105–118, 2006. ISSN 10440283. doi: 10.1016/j.gfj.2006.06.002.
- Damian Jorge Matich. Redes Neuronales: Conceptos Básicos y Aplicaciones. *Historia*, page 55, 2001. URL <ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>.
- E. J. Elton and M. J. Gruber. Marginal Stockholder Tax Rates and the Clientele Effect. *The Review of Economics and Statistics*, 52(1):68, 1970. ISSN 00346535. doi: 10.2307/1927599. URL <http://www.jstor.org/stable/1927599?origin=crossref>.
- M. I. A. Galipienso, M. A. C. Quevedo, O. C. Pardo, F. E. Ruiz, and M. A. L. Ortega. *Inteligencia artificial: modelos, técnicas y áreas de aplicación*. Editorial Paraninfo, 2003.
- D. N. Gujarati and D. C. Porter. *Econometría*. 5 edition.
- M. Gutiérrez, M. Yañez, and B. Umaña. Análisis de la política de pago de dividendos en empresas chilenas. *Estudios gerenciales*, 28(11):27–42, 2012. doi: 10.1007/s00415-003-0182-5.
- F. Izaurieta. Redes Neuronales Artificiales. pages 1–15.
- W. Kristjanpoller. Análisis del efecto día de semana en los mercados accionarios latinoamericanos. *Lecturas de economía*, 71(71):189–207, 2009. ISSN 0120-2596. URL [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S0120-25962009000200007&lng=en&tlng=es](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-25962009000200007&lng=en&tlng=es).

- W. Kristjanpoller. El efecto fin de mes en los principales mercados accionarios latinoamericanos. 60(1):53–86, 2015. doi: 10.1016/S0186-1042(15)72147-9.
- R. F. López and J. M. F. Fernandez. *Las redes neuronales artificiales*. Netbiblo, 2008.
- C. Maquieira and D. Osorio. Anuncios de cambios en pagos de dividendos y su impacto en la riqueza de los accionistas : evidencia empírica en Chile. *Estudios de Administración*, 7(1): 1–26, 2000. ISSN 07170653. doi: Article.
- J. M. Marín Diazaraque. Introducción a las redes neuronales aplicadas. *Manual Data Mining*, pages 1–31, 2007. URL [halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/DM/tema3dm.pdf](http://halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/DM/tema3dm.pdf).
- J. Mascareñas. *La política de dividendos*. PhD thesis, Universidad Complutense de Madrid, 2011.
- E. Muñoz and A. Rodriguez. Ex-dividend date stock behavior and the clientele effect: Evidence around a tax reduction. *Global Finance Journal*, 32:55–61, 2017. ISSN 10440283. doi: 10.1016/j.gfj.2016.06.003. URL <http://dx.doi.org/10.1016/j.gfj.2016.06.003>.
- M. Nash and D. Fuenzalida. The Effect of Dividend Distribution on Share Return in Chile. *Estudios Gerenciales*, 093:99–113, 2004.
- J. Núñez, J. Rositas, and M. M. Elizondo. Modelo de política óptima de dividendos ( Model for a dividend optimal policy ) Introducción Cualquier pago directo de la corporación a los accionistas forma parte de la política de dividendos . El tipo más común de dividendo es en efectivo Un excelente p. 10(20):251–273, 2013.
- M. G. Urzúa and D. Ph. Análisis de la política de pago de dividendos en empresas chilenas 1. *Estudios Gerenciales*, 28(123):27–42, 2012. doi: 10.1016/S0123-5923(12)70203-6. URL [http://dx.doi.org/10.1016/S0123-5923\(12\)70203-6](http://dx.doi.org/10.1016/S0123-5923(12)70203-6).
- F. Villada and N. Muñoz. Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores Application of Artificial Neural Networks to Price Forecasting in the Stock Exchange Market. 23:11–20, 2012. doi: 10.4067/S0718-07642012000400003.