



**Universitat Autònoma
de Barcelona**

TÍTULO DEL TFG: Rendimiento de un modelo basado en redes neuronales respecto a métodos estadísticos estándar en la predicción de datos financieros

AUTOR DEL TFG: JOSE IGNACIO MARTÍ GIL

GRADO: CONTABILIDAD Y FINANZAS

TUTOR DEL TFG: DAVID MORIÑA SOLER

26 DE ENERO DE 2018

Agradecimientos: Quisiera agradecer la profesionalidad, el rigor, la dedicación y la humanidad del claustro de profesores del campus de Sabadell de la UAB. En especial, a David Moriña Soler, por su confianza y predisposición para desarrollar el presente proyecto más allá de los límites iniciales. También a Javier Caro, Senior Manager de GPMBroker, por haber aportado su experiencia en el mercado financiero, así como el acceso a recursos tecnológicos.

ÍNDICE DE CONTENIDO

1. RESUMEN.....	2
2. INTRODUCCIÓN	3
3. MÉTODOS	9
3.1. Método estadístico estándar	9
3.2. Red neuronal	13
3.3. Herramientas auxiliares.....	14
3.4. Herramienta web.....	15
4. RESULTADOS	23
4.1. Método estadístico estándar	23
4.2. Red neuronal	24
5. CONCLUSIONES.....	26
6. BIBLIOGRAFÍA.....	27

1. RESUMEN

El objetivo del presente trabajo de final de grado es analizar y determinar si un modelo basado en redes neuronales puede mejorar el rendimiento de los modelos estadísticos clásicos en la detección de determinados patrones en la evolución temporal de valores bursátiles, aportando una mayor rentabilidad al predecir el mercado con unos niveles de riesgo similares o inferiores.

Para ello, se compararán los resultados del modelo estadístico clásico frente al modelo neuronal, en función de los parámetros siguientes:

- Beneficio Neto por operación realizada.
- Desviación Típica, entendida como la dispersión de los resultados respecto de su media.
- Eficacia del modelo, entendida como el número de operaciones ganadoras respecto del total de operaciones propuestas. Se entenderá operación ganadora como aquella cuyo resultado sea positivo y logre compensar los costes del broker.

Para ilustrar el funcionamiento de las metodologías propuestas se estudiará como ejemplo el rendimiento obtenido a través de cada una de ellas para la acción de Apple durante el periodo 2000-2017.

En este caso, se observa que el sistema neuronal propone más operaciones que el sistema basado en el método estadístico clásico (158 por 17), tiene una mayor eficacia, tiene mayor beneficio neto y una dispersión menor. Los detalles se muestran en la Tabla 1. Los resultados se han obtenido a partir de datos históricos, descargados desde un repositorio gratuito web conocido como "quandl.com", que contiene información económico-financiera de diferentes mercados.

Para simplificar la tarea de recogida de información, tratamiento de datos y muestra de resultados, se ha construido una aplicación web basada en el lenguaje de programación R.

2. INTRODUCCIÓN

A lo largo de los años, el mercado financiero siempre ha sido reconocido por la gran competitividad que existe entre sus inversores. Sin embargo, en los últimos años, debido a la facilidad con que éstos pueden acceder a determinados productos que antes sólo se ofrecían a unos pocos, los costes y tiempos de acceso al mercado se han visto reducidos. De esta forma, la competitividad se ha incrementado, así como la necesidad de encontrar *ventajas competitivas* que permitan a los inversores sobresalir en un ambiente de creciente rivalidad.

Esta ventaja se encuentra en el buen uso de la tecnología como elemento diferenciador. Un ejemplo podría ser la decisión última de los mercados de alojar equipos informáticos en las Bolsas¹, con el fin de reducir el tiempo de ejecución de determinadas operaciones.

Al margen de esto, la realidad es que los inversores han vivido una revolución en términos de reducción de coste, tiempo de ejecución y de acción, así como de estandarización de la información disponible, entre otras cosas.

En los años 90 se consideraba adecuado que las órdenes se enviaran al mercado por vía telefónica o fax, pudiendo retrasar la ejecución de la operación hasta tres días o más, dependiendo de si la transacción se realizaba sobre un activo nacional o uno extranjero. Tampoco existía la certeza de que la orden llegara al mercado, debido a los recorridos burocráticos a los que debía ser sometida.

A día de hoy, tanto el uso de Internet como el de la Tecnología han acercado continentes, otorgando, a su vez, la capacidad de comprar o vender acciones, futuros, divisas y otros activos con tan sólo un click del ratón.

Otros agentes aceleradores de estos procesos han sido los *Brokers*, quienes facilitan información limpia y transparente (según si se trata de mercados regulados o no), y

¹ <https://www.speedytradingsservers.com>

ofrecen costes de ejecución similares, además de la certeza de la ejecución inmediata de las órdenes.

Por último, con tantas facilidades, es importante buscar ventajas competitivas, pero para ello se debe tener en cuenta cuál es la primera impresión del mercado. Si se observa el precio histórico completo de los índices financieros desde su creación, se puede determinar con facilidad que existe una tendencia alcista. También se aprecia que la volatilidad aumenta, entendiéndose como la variación de los precios a día de hoy en relación a sesiones anteriores.



S&P500, GRÁFICOS MENSUALES 1965 - 2016²

Existen toda clase de estudios que intentan dar explicación al comportamiento de los mercados financieros (*Malkiel, 1973*), pero en este trabajo sólo se hará referencia a dos principales corrientes, las cuales definen diferentes perspectivas de análisis en relación a qué tipo de datos se ha de prestar atención para evaluar el comportamiento futuro de un valor³. Dichas corrientes son las siguientes:

- El Análisis Técnico:

Los analistas técnicos⁴ sostienen que toda información referente a una acción o acciones está contenida en el análisis histórico del precio y del volumen, considerando que el precio refleja las posiciones tomadas por el inversor, tanto si éste es grande como si es pequeño.

² Imagen obtenida desde la página web <https://es.investing.com/indices/us-spx-500-advanced-chart>

³ <https://www.rankia.com/blog/secretosbolsa/783139-analisis-tecnico-fundamental-ambos-ninguno>

⁴ <https://www.rankia.com/blog/bolsa-desde-cero/3151922-conceptos-basicos-analisis-tecnico>

Esta corriente de pensamiento puede dividirse a su vez en dos escuelas; la de análisis de los gráficos (Chartistas), y la de los análisis por medio de indicadores estadísticos y osciladores (Técnicos).

- El Análisis Fundamental:

Los analistas fundamentales⁵ recurren a la evaluación de la empresa y de su entorno económicos para obtener el valor verdadero de la empresa. Es un enfoque basado en el *largo plazo*, ya que estos analistas sostienen que el precio de las acciones se acercará al valor real de la empresa en *un periodo de tiempo largo*.

Llegados a este punto, existen múltiples definiciones del valor verdadero de una empresa y diversas formas de calcularlo, cuál de ellas más compleja, sobre todo por la información requerida para ello.

Por otro lado, resulta cada vez más complicado tomar decisiones en base a indicadores técnicos y observaciones del pasado –debido al aumento de volatilidad de las acciones– que el adoptar una perspectiva de análisis fundamental; a pesar de que el primer método, basado en la recopilación de información, requiera menos recursos económicos para su aplicación.

Precisamente por esto, a las dos corrientes de análisis financiero previamente mencionadas podemos añadir el afloramiento del Análisis Cuantitativo⁶ – en forma de modelos computacionales complejos– como una forma *evolucionada* del pensamiento técnico.

Este último, gracias a la incorporación de equipos informáticos baratos y potentes, y con la ayuda de una revolución tecnológica en auge; ha dado pie y popularidad al estudio y uso de Inteligencias Artificiales como un medio innovador para encontrar con mayor rapidez y eficacia, el mejor momento para intervenir en los mercados financieros.

⁵ <https://www.rankia.com/blog/bolsa-desde-cero/2325458-principios-basicos-analisis-fundamental>

⁶ [https://es.wikipedia.org/wiki/Análisis_cuantitativo_\(finanzas\)](https://es.wikipedia.org/wiki/Análisis_cuantitativo_(finanzas))

Es precisamente por esto que se ha elegido comparar cuál es la relación rentabilidad/riesgo de un activo en concreto, usando dos sistemas distintos. El primero será basado en el cálculo de patrones estadísticos, y el segundo, se llevará a cabo dejando que una Inteligencia Artificial determine los movimientos a realizar.

Sin embargo, y considerando la facilidad con la que podremos obtener la información adecuada para llevar a cabo el estudio, se ha optado por trabajar desde la perspectiva del Análisis Técnico, usando los precios históricos diarios al cierre de Apple, Inc., como ilustración del rendimiento de los métodos considerados.

Antes de comenzar, no obstante, es preciso obtener una base de datos robusta, de calidad, con pocos *agujeros* en los datos, amplia, y representativa. Además, no debe tener restricciones de uso en términos legales y, por si fuera poco, será necesario que esta fuente sea gratuita y fácil de usar; debido a la naturaleza de la investigación del presente trabajo.

Como respuesta a esta pregunta surgen varias alternativas naturales como Google Finance y Yahoo Finance, pero ambas cuentan con restricciones legales, ya que los datos que contienen provienen de las bases de datos adquiridas a proveedores de datos oficiales, y reservan dicha información sólo a usuarios de pago. También se limitan el número de conexiones diarias y mensuales, por lo que se escoge, finalmente, por buscar una fuente alternativa de datos.

La solución llega de la mano de Quandl, con repositorios del ámbito económico-financiero gratuitos y de pago. Con el registro gratuito, se da la capacidad de realizar más de 2.000 descargas diarias (un volumen más que suficiente para cubrir las necesidades del proyecto), con la posibilidad de integrarlas directamente al lenguaje de programación R, y sin restricciones legales que puedan limitar el desarrollo futuro de la aplicación. De entre sus opciones, se escoge la base de datos WIKI⁷ que permite la descarga de datos al cierre de 3.000 compañías americanas.

⁷ <https://www.quandl.com/databases/WIKIP>

Dado que Quandl vende sus bases de datos –y su negocio depende de la calidad de la información suministrada–, la misma empresa audita la veracidad de dicha información. También existen usuarios que colaboran con Quandl para mantener las bases de datos gratuitas actualizadas.

Paralelamente, se han realizado verificaciones con muestras de las bases de datos obtenidas a lo largo de un periodo de prueba con NinjaTrader⁸; una de las principales plataformas de *operativa retail*, y que ofrece servicios de *broker* para la compra y venta de activos financieros.

Por último, y una vez superada la problemática de obtener una fuente de información sólida y consolidada, se procede a exponer razones o motivadores que justifiquen el uso de patrones estadísticos como punto de origen para determinar una estrategia base. Intentar estimar cuál es el patrón de comportamiento de una acción no es algo nuevo. Existen múltiples fuentes de libre consulta en internet (por ejemplo, *H. V. Roberts, 1959*) que intentan atraer la atención hacia el estudio estadístico del comportamiento de las acciones tras una previsualización empírica. Ésta no sólo resalta la importancia de estudiar las variaciones del precio, sino que también señala niveles concretos de operativa. Se pueden encontrar también estudios contemporáneos que intentan abordar la estimación del precio de las acciones en base a patrones estadísticos (por ejemplo, *Vandana Gariney, 2002*).

A partir de mediados de los años 90 empiezan a surgir trabajos que proponen algoritmos de aprendizaje computacional para analizar este tipo de datos. Una buena referencia introductoria puede ser *Tom M. Mitchell, 1997*.

En 2013, el departamento de ciencia computacional de la Universidad de Iowa publicó un estudio acerca de la predicción del precio de acciones usando el sentimiento de los inversores mediante algoritmos de aprendizaje supervisados⁹. Para ello, capturaron los comentarios de distintos foros de inversión de Google y Yahoo, dividiéndolos en cinco

⁸ <https://ninjatrader.com>

⁹ <https://content.iospress.com/articles/algorithmic-finance/af025>

categorías según la recomendación dada (firme posición de compra, compra, mantener en cartera, venta, firme posición de venta).

El presente trabajo pretende demostrar que no solamente existen estudios previos acerca de la aplicación de patrones estadísticos de comportamiento en acciones, sino que también existe una corriente de desarrollo en la actualidad que puede constituir un punto de partida para contraponer los resultados obtenidos mediante esta técnica frente a aquellos que se puedan obtener mediante la implementación de una Inteligencia Artificial.

3. MÉTODOS

En este trabajo se han construido dos sistemas de operativa en los mercados financieros, partiendo desde cero. Ninguno de los dos sistemas que se presentarán han sido sometidos a la operativa con dinero real, aunque sí se han ejecutado con un simulador que se ha construido a tal efecto y usando precios históricos diarios.

Ambos sistemas procesarán la información de la acción de la compañía Apple, Inc. del índice del Nasdaq 100, tomando todo el periodo comprendido entre el año 2000 hasta la última cotización del pasado año 2017. Se trabajará exclusivamente con el precio al cierre de la acción, con el objetivo de simplificar los procesos de cálculo y los modelos que se han diseñado.

3.1. MÉTODO ESTADÍSTICO ESTÁNDAR

Teniendo en cuenta que la volatilidad de una acción es importante hasta el punto en que un solo día puede arruinar los resultados de todo un año, se ha definido que la volatilidad de la acción ha de permanecer dentro de un rango habitual en base a la desviación típica diaria de los precios al cierre.

Se supondrá, además, que la dispersión del promedio de los precios al cierre sigue una distribución normal, como principio básico para determinar la posibilidad de realizar una entrada en la acción con una confianza del 95%. Esta asunción de normalidad de los precios con un nivel de confianza del 95%, en una distribución normal centrada en 0, implica que la desviación típica no puede ser inferior a -2 ni superior a 2.

Por último, la media de los precios debe seguir una tendencia determinada, ya sea ascendente o descendente, durante un número determinado de sesiones a partir de la fecha de la entrada realizada. Se cerrará la posición cuando se detecte que se van a producir un mínimo de dos sesiones con tendencia opuesta a la posición tomada. Para cerrar la posición, no se tomará en cuenta la volatilidad, sólo el valor promedio de los precios.

No obstante, antes de proceder con el diseño del sistema, se deberán transformar los datos, pues sucede que la cotización de una acción tiene precios diferentes de año en año, y no están estandarizados; por lo que es fundamental proceder a una

estandarización anualizada de los precios, ya que se quiere determinar si hay comportamientos que se cumplan cíclicamente cada año. Para ello, se dividirá la serie temporal en años.

Se han determinado dos procedimientos para estandarizar¹⁰ una variable aleatoria:

- **Escalado MinMax:**

$$Apple_{norm} = \frac{Apple_{precio\ diario} - Min(Apple)_{Anual}}{Max(Apple)_{Anual} - Min(Apple)_{Anual}}$$

Se divide la diferencia entre el precio de la sesión de Apple, menos el mínimo de cotización anual, y todo ello entre la diferencia del precio máximo y mínimo registrado en cada año. Con este método se consigue modificar la escala de valores entre 0 y 1, siendo 0 el valor mínimo, y 1 el valor máximo.

- **Escalado Estándar:**

$$Apple_z = \frac{Apple_{precio\ diario} - Apple_{media\ anual}}{Apple_{desviación\ típica\ anual}}$$

Con este procedimiento de estandarización se obtiene una distribución normal de la serie con una media centrada en 0.

Para la realización del presente trabajo, se utilizará la normalización basada en el escalado MinMax por los motivos siguientes:

- El Escalado Estándar arroja valores negativos
- El Escalado MinMax permite comparar las series anuales tipificadas con un rango concreto entre 0 y 1, mientras que el Escalado Estándar no tiene límites inferiores o superiores; debiendo introducir factores correctivos para poder comparar cuál ha sido la evolución del valor en el mismo día respecto de otros años.

¹⁰ <http://www.synergicpartners.com/precauciones-a-la-hora-de-normalizar-datos-en-data-science/>

Para ello, se multiplicará la serie normalizada por 100 para reducir el ruido fruto de la normalización, obteniendo una serie temporal con un rango situado entre 0 y 100 para cada uno de los años con los que se cuente con datos históricos; siendo el primero el valor mínimo de la acción para ese año y, siendo el último, el valor máximo anual.

Por otro lado, el calendario gregoriano está compuesto de 365 días, siendo sólo 248 de operativa en el mercado. Sin embargo, cada 4 años se añade 1 día más al calendario, generando 249 días operativos en el mercado financiero.

Dado que estamos trabajando con sistemas matriciales, tener un día extra de información cada 4 años requeriría de otras manipulaciones de los datos. Además, puede influir en la toma de decisiones, ya que el sistema se basa en el cálculo de la media y de la desviación típica de los precios diarios tipificados según su evolución anual.

Por esto mismo, de ahora en adelante, el primer día de la serie temporal anual representará el primer día del nuevo año en el que tenemos datos nuevos, con independencia del día de la semana que represente, ya que se asume que el calendario viene determinado según convenciones históricas, y como es habitual que el calendario disponga de 248 días hábiles, se eliminará del estudio el dato sobrante sin mayores repercusiones. De este modo, la media anual se calculará de acuerdo a la expresión

$$Apple_i = \frac{\sum_{i=1}^n \text{precio dia}_i \text{ de cada año}}{n \text{ años}}$$

El procedimiento para calcular la media diaria será el siguiente:


$$\text{Precio primer dia} = \frac{\text{Precio primer dia año 2000} + \text{Precio primer dia año 2001} + \dots + \text{Precio primer dia año } n}{\text{Número de años}}$$

$$\text{Precio segundo dia} = \frac{\text{Precio segundo dia año 2000} + \text{Precio segundo dia año 2001} + \dots + \text{Precio segundo dia año } n}{\text{Número de años}}$$

$$\text{Precio tercer dia} = \frac{\text{Precio tercer dia año 2000} + \text{Precio tercer dia año 2001} + \dots + \text{Precio tercer dia año } n}{\text{Número de años}}$$

$$\text{Precio } n \text{ dia} = \frac{\text{Precio } n \text{ dia año 2000} + \text{Precio } n \text{ dia año 2001} + \dots + \text{Precio } n \text{ dia año } n}{\text{Número de años}}$$

Se generará un número determinado de medias de 248 días gracias a las n series temporales, representando una simplificación del comportamiento pasado de la acción y que usaremos para determinar cuál puede ser el comportamiento esperado en el futuro.



También se creará un número determinado de medias históricas (4 por defecto), a parte de la media para el presente año, con el objetivo de ver una evolución de las medias tras la incorporación de nuevos datos.

La desviación típica (s) es una medida de dispersión que mide cuál es la distancia de una observación respecto a su media.

$$S_i \text{ Apple} = \frac{1}{n-1} \sqrt{\sum_{i=1}^n (\text{Apple}_i - \text{Media}_{\text{Apple}})^2}$$

Siendo $n=4$ (2013, 2014, 2015, 2016) y Apple_i el precio a un día determinado para cada una de las medias con las que hemos construido el pronóstico del presente año, obteniendo una serie de 248 desviaciones típicas, para cada día laboral.

Por otro lado, se han establecido los condicionantes siguientes:

- Se define que el precio debe comportarse siguiendo una distribución normal con un nivel de confianza de 95%, lo cual determina el límite con valor absoluto de 2 para la desviación típica. Si la dispersión supera dicho valor absoluto, entonces no será posible realizar una orden de entrada para esa acción.
- Si se cumple el primer supuesto, la media deber seguir una tendencia por un número mínimo de días. Se fija que, al menos, el precio debe crecer o disminuir por 3 días consecutivos.

- Si se observa que el precio puede seguir una tendencia opuesta respecto a la posición tomada por dos días consecutivos, entonces se cerrará la posición el último día en que se supone, a nivel estadístico, que el precio vaya a avanzar según el interés de la orden enviada.

En base a las condiciones impuestas, buscamos un rango de días en que:

- El primer día de ejecución tenga una volatilidad histórica baja, siguiendo una distribución normal.
- Los siguientes 2 días tengan una tendencia definida año a año.

3.2. RED NEURONAL

El presente trabajo no pretende hacer una exposición detallada de cómo construir una Inteligencia Artificial, pero sí presentará una breve introducción a ésta recurriendo a literatura existente sobre el tema como, por ejemplo, el Perceptron¹¹, que es el modelo de red neuronal más pequeño que existe, constituido por una sola neurona que define una relación lineal entre un vector como input, y devuelve un output con un único valor, pudiendo éste tomar valores finales de 0 o 1.

Existen dos áreas principales del aprendizaje computacional:

- Aprendizaje supervisado:
 - 1) Se produce un rastreo previo de las propiedades de los datos, antes de enviarlos al sistema.
 - 2) Se facilita al sistema una función que ha de optimizar en base a una serie de inputs.
 - 3) Se fragmenta el histórico para determinar uno o varios periodos de aprendizaje con el que se entrenará el programa.

¹¹ <https://es.wikipedia.org/wiki/Perceptrón>

- 4) Finalmente, se prueba el desempeño sobre otras series temporales distintas y se evalúan divergencias en relación al conjunto de datos usados para su entrenamiento.

El escenario ideal es aquel en que el programa es capaz de reconocer nuevos movimientos gracias al entrenamiento de la fase de aprendizaje con tanto acierto como sea posible (superior al 50%) y con la menor desviación. Dados unos inputs, el sistema es capaz de predecir el resultado.

- Aprendizaje no supervisado

No hay estudio a priori de la información ni una evaluación previa, sino que la propia inteligencia infiere los patrones derivados de la información e intenta obtener un conocimiento para construir su propia función.

Los programas de aprendizaje no supervisado son más rápidos al no requerir de la estructuración previa de la información, pero debido a que no pueden ser verificados con anterioridad y a que no se conoce la función de optimización (ya que se construye directamente por el programa), sus resultados pueden llegar a ser imprevisibles.

En este trabajo se aplicará el aprendizaje supervisado, debido al control que se ostentaría de la función que aplicará el sistema. Además, es deseable que haya un periodo de prueba de la estrategia, con el fin de comparar los resultados del mismo periodo con los obtenidos por el método estadístico estándar previamente expuesto.

3.3. HERRAMIENTAS AUXILIARES

Con la intención de facilitar la recogida de información de los resultados de ambas estrategias, se ha construido una herramienta web en base al lenguaje de programación R, ya que ésta permite la manipulación de grandes cantidades de datos.


Para construir el entorno web se ha usado el paquete de programación conocido como “Shiny” (*Chang et al., 2017*), y el paquete denominado “Neuralnet” (*S. Fritsch y F. Guenthe, 2016*), que permite la configuración de una Red Neuronal en el lenguaje de programación R.

3.4. HERRAMIENTA WEB

La página web se compone de los siguientes elementos:

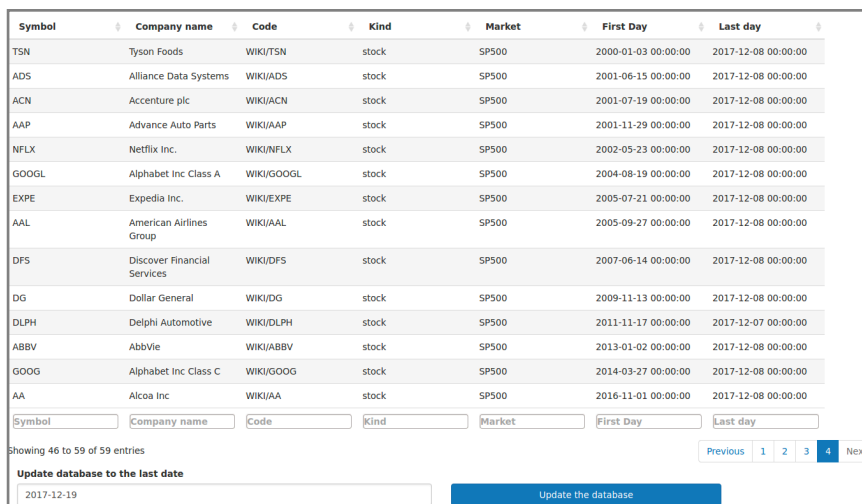
- Página de carga

Durante la carga de la aplicación, se muestra un mensaje de espera hasta que todos los elementos han sido creados. El proceso suele durar menos de 35 segundos para procesar más de 200.000 registros, ejecutar consultas a la base de datos, y construir los elementos de interacción.



- Base de datos

En la base de datos podemos observar el ticker de la acción, el nombre de la compañía asociada, tipo de activo, mercados a los que pertenece el activo y el rango de la primera y última fecha de datos a disposición en la base de datos (MySQL).



The image shows a table with columns: Symbol, Company name, Code, Kind, Market, First Day, and Last day. Below the table are search filters for each column and a pagination bar showing 'Showing 46 to 59 of 59 entries' with buttons for 'Previous', '1', '2', '3', '4', and 'Next'. At the bottom, there is a section for 'Update database to the last date' with a date input field and an 'Update the database' button.

Symbol	Company name	Code	Kind	Market	First Day	Last day
TSN	Tyson Foods	WIKI/TSN	stock	SP500	2000-01-03 00:00:00	2017-12-08 00:00:00
ADS	Alliance Data Systems	WIKI/ADS	stock	SP500	2001-06-15 00:00:00	2017-12-08 00:00:00
ACN	Accenture plc	WIKI/ACN	stock	SP500	2001-07-19 00:00:00	2017-12-08 00:00:00
AAP	Advance Auto Parts	WIKI/AAP	stock	SP500	2001-11-29 00:00:00	2017-12-08 00:00:00
NFLX	Netflix Inc.	WIKI/NFLX	stock	SP500	2002-05-23 00:00:00	2017-12-08 00:00:00
GOOGL	Alphabet Inc Class A	WIKI/GOOGL	stock	SP500	2004-08-19 00:00:00	2017-12-08 00:00:00
EXPE	Expedia Inc.	WIKI/EXPE	stock	SP500	2005-07-21 00:00:00	2017-12-08 00:00:00
AAL	American Airlines Group	WIKI/AAL	stock	SP500	2005-09-27 00:00:00	2017-12-08 00:00:00
DFS	Discover Financial Services	WIKI/DFS	stock	SP500	2007-06-14 00:00:00	2017-12-08 00:00:00
DG	Dollar General	WIKI/DG	stock	SP500	2009-11-13 00:00:00	2017-12-08 00:00:00
DLPH	Delphi Automotive	WIKI/DLPH	stock	SP500	2011-11-17 00:00:00	2017-12-07 00:00:00
ABBV	AbbVie	WIKI/ABBV	stock	SP500	2013-01-02 00:00:00	2017-12-08 00:00:00
GOOG	Alphabet Inc Class C	WIKI/GOOG	stock	SP500	2014-03-27 00:00:00	2017-12-08 00:00:00
AA	Alcoa Inc	WIKI/AA	stock	SP500	2016-11-01 00:00:00	2017-12-08 00:00:00

Al pulsar sobre el botón *Actualizar la base de datos*, el programa descarga el último dato disponible en el repositorio gratuito de quandl.com, usando como referencia la fecha que aparece al lado. Por defecto, el sistema recoge la fecha actual del servidor, si bien el usuario es capaz de modificar la fecha de actualización.

Por último, permite añadir símbolos para descargar información desde el repositorio web y que éstos sean incorporados en la base de datos propia.

- Estrategias

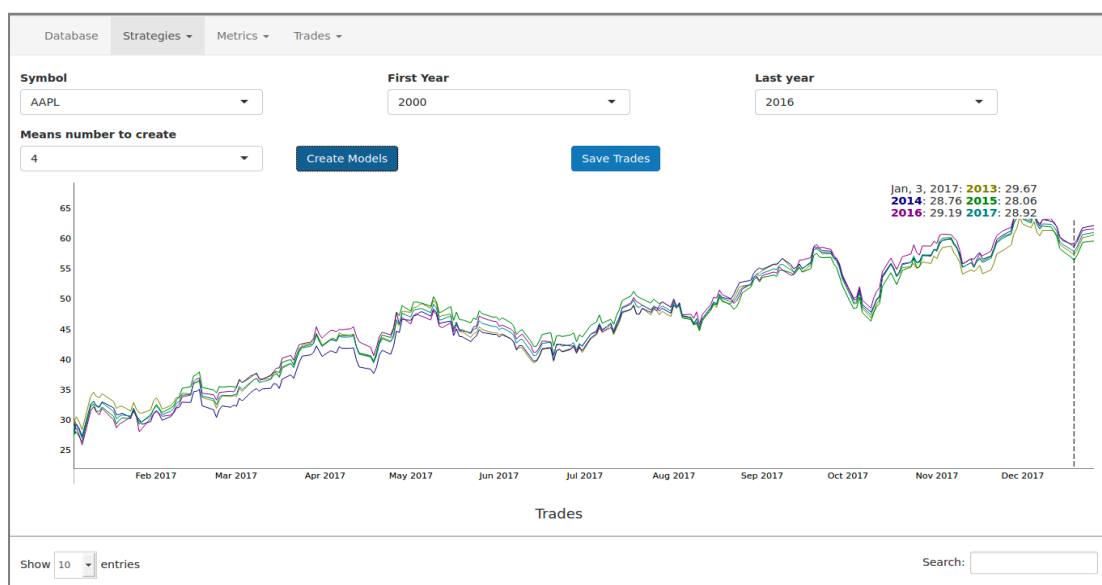
En la pestaña de Estrategias hay un menú desplegable que recoge la ejecución de ambas estrategias. La interfaz permite seleccionar sobre qué activo realizar el estudio, así como un gráfico que recoge el comportamiento propio de cada estrategia para su estudio preliminar a nivel visual, y una tabla que resume la fecha de la siguiente posición a tomar, qué se debería hacer con ese activo, y otra información que se ha considerado relevante mostrar en el pre-análisis.

- Patrones estadísticos

Se permite seleccionar el activo sobre el que realizar el estudio de patrones estadísticos, tal y como definimos en la sección *Método estadístico estándar* de este trabajo. También permite seleccionar el rango de años sobre el que realizar el estudio para generar la previsión del presente año.

Por último, permite seleccionar el número de medias a usar para generar la previsión.

Con el botón *Crear Modelos* se activa la generación del modelo. Si la estrategia nos parece convincente, podemos guardar las posiciones a tomar pulsando sobre *Guardar Operaciones*.



En la siguiente esta tabla, el programa nos muestra la fecha de ejecución, qué número de día laboral representa respecto los 248 días laborales en el mercado, qué tipo de movimiento se ha de realizar (compra, venta, giro a compra, giro a venta, cierre de largo, cierre de corto). Con el objetivo de mejorar la previsualización, se añade el resultado de la media esperada para el presente año en la fecha dada.


Date	Business day Index	Action to take	Mean price value	Symbol
2017 10 05	192	T_SELL	51.37	AAPL
2017 10 09	194	T_BUY	47.5	AAPL
2017 10 16	199	T_SELL	55.81	AAPL
2017 10 18	201	T_BUY	53.79	AAPL
2017 11 06	214	T_SELL	59.98	AAPL
2017 11 14	220	T_BUY	55.52	AAPL
2017 11 30	231	T_SELL	64.66	AAPL
2017 12 19	244	T_BUY	57.97	AAPL
2017 12 26	248	C_BUY	61.08	AAPL

Showing 31 to 39 of 39 entries

- Red neuronal

Se puede escoger qué activo usar en la Red Neuronal y qué rango de años va a usarse para generar la predicción según el histórico disponible en la base de datos propia.

Al pulsar sobre el botón *Activar neurona* se ejecuta la Red Neuronal, que acabará por generar un gráfico como el que sigue y una tabla que mostrará información relevante.



La tabla que se genera en esta estrategia limita la información que muestra, ya que el objetivo de la Red Neuronal es pronosticar el sentido, no así el precio. Se ha de tomar en consideración que, cuánto mayor sea el rango de tiempo que se desee pronosticar, mayor puede ser la desviación respecto la realidad.

En la siguiente tabla se muestra la fecha de ejecución, qué número de día laboral se trata respecto a los 248 hábiles, y qué tipo de acción se debe realizar.

Trades		
Show 10 entries		Search: <input type="text"/>
Date	Business day Index	Action to take
2017-11-21	223	SELL
2017-11-29	228	BUY
2017-11-30	229	SELL
2017-12-04	231	BUY
2017-12-05	232	SELL
2017-12-06	233	BUY
2017-12-11	236	SELL
2017-12-12	237	BUY
2017-12-13	238	SELL
2017-12-14	239	BUY
2017-12-18	241	SELL
2017-12-21	244	BUY
2017-12-22	245	SELL
2017-12-29	249	BUY

- Métricas

Se desea comparar cuál ha sido el desempeño de las estrategias a partir del resultado de las operaciones realizadas por ambas. Con este objetivo en mente, se ha diseñado un resumen global y otro individualizado por cada activo presente en nuestra base de datos, y sobre el que se haya realizado alguna operación.

En la sección de resultados se expondrán las métricas más importantes.

Database Strategies Metrics Trades			
Insert date range			
2000-01-01	to	2017-12-19	Show global stats
	Neurona Strategy	Index Strategy	Global
Trades	8322	631	8953
Net Profit	969626	3865	973491
Profits	1014721	73534	1088255
Losses	-45095	-69669	-114764
% Accuracy	86.28	53.25	83.95
Average	116.51	6.13	108.73
Contracts	832200	63100	895300
Ticks	10622.85	27.06	10649.91
Ticks won	11071.66	560.35	11632.02
Ticks lost	-448.82	-533.29	-982.11
Long trades	4167	336	4503
Short trades	4155	295	4450
Long trades Won	3722	198	3920
Short trades Won	3458	138	3596
Best trade	4967	2401	4967
Worst trades	-1259	-3352	-3352
Avg Time in market	54:16:10.7281	182:34:02.4722	63:18:43.0648
Ticks won: Best	25.93	10.93	25.93
Ticks lost: Worst	-9.69	-20.5	-20.5
Avg. Won(€)	141.33	218.85	144.79

- Global

La interfaz permite seleccionar el rango sobre el que realizar la consulta de los resultados obtenidos por ambas estrategias.

Se muestran los resultados globales obtenidos por la red neuronal y por el método estadístico estándar. También se incorpora una columna global.

- Individual

Permite escoger qué activo en específico analizar, así como el rango de fechas sobre el que se realizará el estudio.

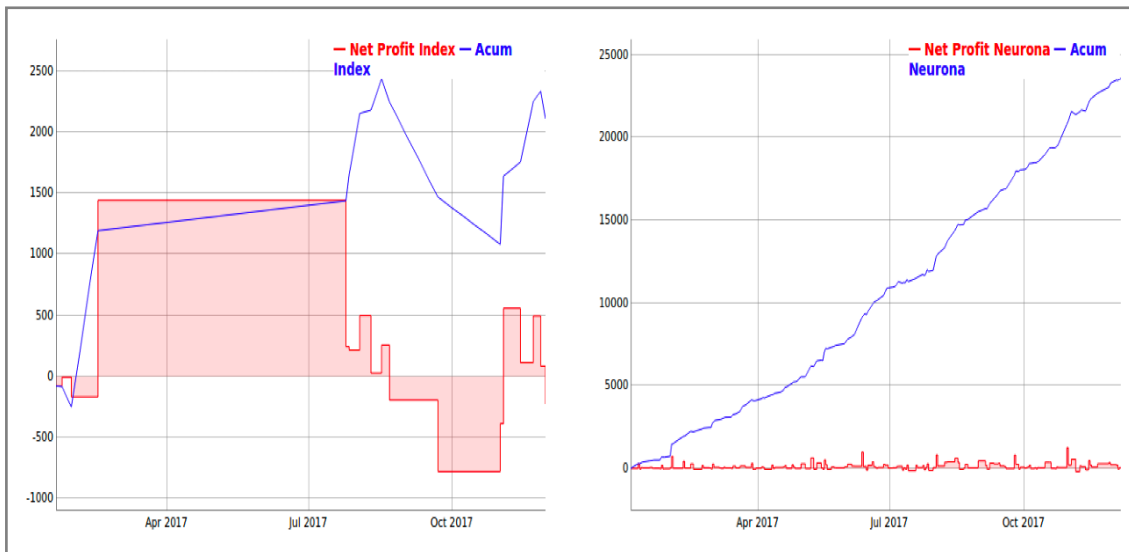
Se añade una sección resumen dedicada a obtener una visión rápida sobre las siguientes operaciones a realizar en el activo:

- Las operaciones planificadas permiten conocer qué día se ha de realizar una operación al cierre en ese activo, la fecha de salida prevista, qué estrategia ha generado esa orden y qué acción se debe realizar.
- Se ve un resumen rápido de la acción en cartera, incluyendo información de su fecha de entrada, así como de su fecha de salida; si es una operación de compra o venta, el precio de entrada y el actual, y qué estrategia ha generado esa operación.

Database		Strategies		Metrics		Trades	
Symbol		AAPL		Get metrics for this market			
Insert date range		2000-01-01 to 2017-12-19					
Scheduled Trades							
First Date	Last Date	Action to take	Strategy				
2017-12-12 00:00:00	2017-12-13 00:00:00	BUY	neurona				
2017-12-18 00:00:00	2017-12-31 00:00:00	C_SELL	index				
Opened Trades							
First Date	Last Date	Action to take	Contracts	Entry Price	Exit Price	Strategy	
2017-12-05 00:00:00	2017-12-18 00:00:00	SELL	100.00	169.64	176.42	index	
2017-12-07 00:00:00	2017-12-12 00:00:00	SELL	100.00	169.45	176.42	neurona	

Se generan, también, dos gráficos de resultados netos antes de impuestos (descontando costes propios de la operación). El gráfico de la izquierda refleja los resultados obtenidos por el método estadístico estándar, mientras que el gráfico de la derecha

muestra los beneficios generados por la estrategia de red neuronal. El área roja representa los beneficios individuales por operaciones, mientras que la línea azul representa el beneficio acumulado.



Por último, se genera una tabla resumen con la información más relevante para determinar el éxito de la estrategia durante el periodo estudiado.

La primera fila de las siguientes dos tablas, muestra los resultados obtenidos por la red neuronal, mientras que la segunda, resume el desempeño del método estadístico estándar.

	Trades	Net Profit	Profits	Losses	% Accuracy	Average	Contracts	Ticks	Ticks won	Ticks lost	Long trades	Short trades	Long trades Won	Short trades Won	Best trade	Worst trades
Neurona Strategy	158	23583	24696	-1113	84.18	149.26	15800	156.2	163.49	-7.28	79	79	69	64	1262	-177
Index Strategy	17	2111	3943	-1832	58.82	124.18	1700	13.96	26	-12.03	9	8	6	4	1443	-778

Avg Time in market	Ticks won: Best	Ticks lost: Worst	Avg. Won(€)	Avg. Loss(€)	Avg. Won(Ticks)	Avg. Loss(Ticks)	Profit factor	LongestPStreak	LongestLStreak	Stand. Deviation
51:20:30.3797	7.47	-1.02	185.68	-44.52	151.06	152.84	22.19	15	2	206.92
145:24:42.3529	10.71	-5.12	394.3	-261.71	151.68	152.27	2.15	6	3	480.77

- Operaciones

Se muestra el conjunto de resultados de operaciones futuras, en cartera y cerradas. Por último, se añade un menú de configuración a aplicar sobre la simulación de los datos.

- Registro de Operaciones:

Operaciones planificadas: Muestra la fecha de entrada y de salida prevista, qué tipo de ejecución se debe realizar, qué activo debe comerciarse, y qué estrategia lo ha generado.

Scheduled Trades				
Show <input type="text" value="10"/> entries	Search: <input type="text"/>			
Entry Date	Closing Date	Action	Symbol	Strategy
2017-12-19 00:00:00	2017-12-26 00:00:00	BUY	A	index
2017-12-19 00:00:00	2017-12-20 00:00:00	BUY	AAPL	neurona
2017-12-19 00:00:00	2017-12-31 00:00:00	BUY	ADBE	index
2017-12-19 00:00:00	2017-12-26 00:00:00	BUY	BDX	index
2017-12-20 00:00:00	2017-12-21 00:00:00	SELL	AAPL	neurona
2017-12-20 00:00:00	2017-12-26 00:00:00	T_SELL	ORLY	index
2017-12-21 00:00:00	2017-12-31 00:00:00	BUY	AAPL	neurona
2017-12-21 00:00:00	2017-12-26 00:00:00	BUY	BLK	index
2017-12-21 00:00:00	2017-12-26 00:00:00	SELL	LOW	index
2017-12-21 00:00:00	2017-12-26 00:00:00	SELL	TSN	index
2017-12-26 00:00:00	2017-12-31 00:00:00	C_BUY	A	index
2017-12-26 00:00:00	2017-12-31 00:00:00	C_BUY	ACN	index
2017-12-26 00:00:00	2017-12-31 00:00:00	C_BUY	BAX	index
2017-12-26 00:00:00	2017-12-31 00:00:00	C_BUY	BDX	index

Operaciones en cartera: Muestra qué operaciones están activas. Incluye la fecha de entrada realizada y la fecha de salida prevista, qué activo, qué tipo de ejecución, el número de contratos comerciados por cada posición, qué estrategia ha activado la orden, y los precios de entrada realizada y de salida prevista.

Opened Trades								
Show <input type="text" value="10"/> entries	Search: <input type="text"/>							
Entry Date	Closing Date	Action	Symbol	Contracts	Entry Price	Last Price	Strategy	
2017-10-03 00:00:00	2017-12-31 00:00:00	C_SELL	ABC	100	82.88	92.40	index	
2017-12-07 00:00:00	2017-12-31 00:00:00	C_BUY	ADI	100	86.11	88.09	index	
2017-10-23 00:00:00	2017-12-31 00:00:00	C_BUY	AEP	100	73.32	75.50	index	
2017-12-06 00:00:00	2017-12-31 00:00:00	C_BUY	BA	100	278.27	296.14	index	
2017-08-21 00:00:00	2017-12-31 00:00:00	C_BUY	BIIB	100	283.15	325.95	index	
2017-11-15 00:00:00	2017-12-31 00:00:00	C_SELL	C	100	71.73	75.67	index	
2017-10-17 00:00:00	2017-12-31 00:00:00	C_BUY	CAH	100	65.08	62.39	index	
2017-11-21 00:00:00	2017-12-31 00:00:00	C_SELL	CAT	100	137.60	149.77	index	
2017-06-19 00:00:00	2017-12-31 00:00:00	C_BUY	D	100	80.37	82.75	index	
2017-09-01 00:00:00	2017-12-31 00:00:00	C_BUY	DE	100	116.14	154.04	index	
2017-02-02 00:00:00	2017-12-31 00:00:00	C_BUY	DOV	100	76.96	99.27	index	
2017-07-25 00:00:00	2017-12-31 00:00:00	C_BUY	EA	100	113.66	107.34	index	
2017-12-08 00:00:00	2017-12-31 00:00:00	C_BUY	ECL	100	135.33	135.84	index	
2017-12-06 00:00:00	2017-12-26 00:00:00	BUY	ED	100	88.47	87.32	index	
2017-11-30 00:00:00	2017-12-31 00:00:00	C_BUY	EIX	100	81.27	70.95	index	

Operaciones cerradas: Resume la fecha de entrada y de salida efectivas, qué estrategia generó la orden, qué activo se comerció, y qué tipo de orden se realizó. También incluye el precio de entrada y de salida efectivos, así como el beneficio neto tras incorporar los costes de la operación propios.

- Parámetros

Se construye una página para incluir parámetros que puedan afectar a la simulación de las órdenes efectuadas. Para tal efecto, se incluye el número de acciones a comprar o vender por cada posición, qué comisión hay por operación realizada, y si hay comisiones adicionales.

La información relativa a los costes se ha extraído del *broker* de futuros y acciones GPMBroker¹².



The screenshot shows a web interface with a navigation bar at the top containing 'Database', 'Strategies', 'Metrics', and 'Trades'. Below the navigation bar, there are three input fields: 'Stock number' with the value '100', 'Commissions per side' with the value '0.01', and 'Optional Fee per side' with the value '0'. A blue button labeled 'Update trades' is located at the bottom left of the form area.

¹² <https://www.gpmbroker.com>

4. RESULTADOS


Cada operación se ha realizado con 100 contratos sobre la acción de Apple, Inc. Las comisiones aplicadas han sido de 1€ cada 100 contratos por ejecución. Se ha usado el año 2017 como referencia para simular la operativa.

Resultados para APPLE Inc (2017)	Nº Operaciones	Nº de contratos	Eficacia	Bº promedio neto (operación)	Desviación típica
Red Neuronal	158	15800	84,18%	149,26 €	206,92
Método Estadístico Estandar	17	1700	58,82%	124,18	480,77

Tabla 1. Comparación de las metodologías consideradas en los valores de las acciones de Apple Inc. en 2017.

4.1. MÉTODO ESTADÍSTICO ESTÁNDAR

Se observa cierta volatilidad en la gráfica de beneficio neto acumulado (línea azul), mostrando un máximo entre Agosto y Septiembre de 2017, tardando 3 meses en recuperar el nivel perdido.



En 2017 se han realizado 17 operaciones, el 58,8% ha tendido una rentabilidad positiva. Por cada operación realizada, se han generado 124,18€ netos de coste. Al comprar/vender 100 acciones por operación, se han movido 1.700 contratos. Los beneficios brutos han sido de 3.943€, mientras que las pérdidas brutas han sumado 1.832€.

	Index Strategy
Trades	17
Net Profit	2111
Profits	3943
Losses	-1832
% Accuracy	58.82
Average	124.18
Contracts	1700
Ticks	13.96

Prácticamente se han realizado el mismo número de operaciones de compra (9) y venta (8). Destaca el hecho de que ha habido más operaciones ganadoras de compra (6 de 9) que operaciones ganadoras de venta (4 de 8).


	Index Strategy
Ticks won	26
Ticks lost	-12.03
Long trades	9
Short trades	8
Long trades Won	6
Short trades Won	4
Best trade	1443
Worst trades	-778
Avg Time in market	145:24:42.3529
Ticks won: Best	10.71
Ticks lost: Worst	-5.12
Avg. Won(€)	394.3
Avg. Loss(€)	-261.71
Avg. Won(Ticks)	151.68
Avg. Loss(Ticks)	152.27
Profit factor	2.15
LongestPStreak	6
LongestLStreak	3
Stand. Deviation	480.77

El factor de beneficio se entiende como el beneficio obtenido respecto una unidad de pérdidas, siendo éste de 2,15.

El mejor resultado ha sido de 1.443 €, y la mayor pérdida individual ha sido de 778€.

El tiempo promedio en el mercado ha sido de 6 días. La desviación estándar de los resultados es de 480,77.

4.2. RED NEURONAL



Destaca la clara tendencia alcista de la curva de beneficio neto acumulado de la red neuronal, ya habiendo descontado los costes derivados de la propia compra/venta. También es claro el aumento del número de operaciones respecto al método estadístico estándar.

Se han realizado 158 operaciones en 2017, dando un beneficio neto total de 23.583€ y con una efectividad del 84,18%, en comparación al 58,8% alcanzado por el método estadístico estándar. El rendimiento promedio neto en término económicos ha sido de 149,26 € por operación realizada.

Destaca que el sistema sólo ha perdido 1.113 € en comparación a los 1.832 € del método estadístico estándar, a pesar de un incremento del 930% del número de operaciones respecto al sistema anteriormente presentado.

Se han ejecutado el mismo número de operaciones de compra y venta (79), de las cuales, 69 operaciones de compra han resultado rentables, y 64 operaciones de venta han obtenido beneficios.

La mejor operación ha sido de 1.262 €, mientras que la mayor pérdida ha sido de 177 euros.

El tiempo promedio en el mercado ha sido de 2 días y 4 horas, representando una reducción considerable de tiempo en el mercado respecto al método estadístico estándar.

El *profit factor* se ha multiplicado por 10 respecto al método estadístico estándar, mientras que la desviación estándar se ha reducido a la mitad, siendo en este caso de 206,92.

	Neurona Strategy
Trades	158
Net Profit	23583
Profits	24696
Losses	-1113
% Accuracy	84.18
Average	149.26
Contracts	15800
Ticks	156.2

	Neurona Strategy
Ticks won	163.49
Ticks lost	-7.28
Long trades	79
Short trades	79
Long trades Won	69
Short trades Won	64
Best trade	1262
Worst trades	-177
Avg Time in market	51:20:30.3797
Ticks won: Best	7.47
Ticks lost: Worst	-1.02
Avg. Won(€)	185.68
Avg. Loss(€)	-44.52
Avg. Won(Ticks)	151.06
Avg. Loss(Ticks)	152.84
Profit factor	22.19
LongestPStreak	15
LongestLStreak	2
Stand. Deviation	206.92

5. CONCLUSIONES

Históricamente el análisis de este tipo de datos se ha basado en modelos estadísticos estándar, aunque teniendo en cuenta los resultados mostrados en el apartado anterior, vemos que la red neuronal realiza más operaciones que el método estadístico estándar (incremento del 930%), otorga un mayor beneficio neto por operación (149 € frente a 124 €), con menor dispersión, y mejor porcentaje de acierto (84,18%). Asimismo, destaca la reducción de tiempo en el mercado por operación al utilizar la red neuronal, reduciendo también el riesgo derivado de la apertura diaria del mercado, suceso conocido como gap de apertura¹³. Por tanto, más allá del ejemplo concreto usado, la adopción de un modelo basado en redes neuronales puede mejorar sensiblemente los resultados obtenidos por una estrategia de operativa en Bolsa.

¹³ <https://esbolsa.com/blog/analisis-tecnico/gap/>

6. BIBLIOGRAFÍA

1. B. G. Malkiel, A Random Walk Down Wall Street. Foundations. 13, 464 (1973).
2. H. V. Roberts, Stock-Market “Patterns” and Financial Analysis: Methodological Suggestions, The Journal of Finance, Volume 14, Issue I (1959)
3. G. Vardana, Statistical Analysis for Daily Forecast of Stock Prices, Oregon (USA), Portland State University (2002)
4. Mitchell, T. M. Machine Learning. Annual Review Of Computer Science 417–433 (1997)
5. Winston Chang, Joe Cheng, JJ Allaire, Yihui Xie and Jonathan McPherson (2017). shiny: Web Application Framework for R. R package version 1.0.3. <https://CRAN.R-project.org/package=shiny>
6. Stefan Fritsch and Frauke Guenther (2016). neuralnet: Training of Neural Networks. R package version 1.33. <https://CRAN.R-project.org/package=neuralnet>