INSTITUTO TECNOLÓGICO DE BUENOS AIRES – ITBA

ESCUELA DE TECNOLOGÍA

Evaluación de condiciones de contexto para la aplicación de redes neuronales a la predicción de precios de un determinado activo bursátil.

AUTOR: Palomero Gustavo Fernando (Leg. Nº 104655)

TUTOR: Mg. Pussetto Lucas.

TESIS PRESENTADA PARA LA OBTENCIÓN DEL TÍTULO DE MAGÍSTER EN EN DIRECCIÓN ESTRATÉGICA Y TECNOLÓGICA (ARGENTINA) Y MASTER EXECUTIVE EN DIRECCIÓN ESTRATÉGICA Y TECNOLÓGICA (ESPAÑA)

BUENOS AIRES

PRIMER CUATRIMESTRE, 2022

Miembros del Jurado:

Agradecimientos.

Quiero agradecer especialmente a aquellas personas que con su apoyo han ayudado a que este trabajo sea posible.

Agradezco al Ingeniero Guillermo Calabrese por el constante apoyo y liderazgo ejercido sobre mi que me ha permitido crecer profesionalmente. Un apoyo que viene desde antes de mi carrera de grado y continúa hasta estos días sin detenerse.

Agradezco al Mg Lucas Pussetto por el seguimiento y tutelaje, la enorme ayuda prestada con eterna paciencia y sabios consejos.

Agradezco especialmente a mi familia, mi esposa María de los Ángeles Pafundi y mi hijo Franco Palomero por el constante apoyo.

Contenido

1. Abstract. 10
2. Presentación y antecedente del tema de investigación. 10
3. Objetivos generales y específicos. 13
4. Metodología. 13
5. Limitaciones y Restricciones. 14
6. Marco Teórico 15
6.1. Conceptos iniciales 15
6.1.1. Aproximación de funciones matemáticas. 15
6.1.2. Interpolación de funciones matemáticas 16
6.1.2. Extrapolación de funciones matemáticas. 17
6.1.3. Machine Learning 18
6.1.3.1. Campo de aplicación del machine learning. 18
6.1.3.2. Tipos de estrategias de machine learning. 19
6.1.4. Redes Neuronales Artificiales 20
6.1.4.1. Definición y funcionamiento 20
6.1.4.2. Formulación del comportamiento de una red neuronal. 24
6.1.4.3. Perceptron 25
6.1.4.4. Entrenamiento de la red neuronal. 26
6.1.4.5. Descenso del gradiente. 27
6.1.4.6. Redes Neuronales Recurrentes. 31
6.1.4.7. Celda LSTM 32
6.1.4.8. Celda GRU 34
6.1.5. Síntesis Redes Neuronales. 34
6.2. Lenguajes y productos utilizados. 35
6.3. Macroeconomía, definición y vinculación con los mercados bursátiles 39
6.4. Variables de la macroeconomía seleccionadas para la investigación. 49
7. El Proyecto 49
7.1. Equipamiento utilizado. 50
7.2. Orígenes de los datos de trabajo. 52
7.3. Tratamiento de la entrada de la serie de precios para entrenar una red LSTM. 54
7.4. Separación de los conjuntos de datos 55

7.5. Primera prueba. 56
7.6. Iteraciones en búsqueda de mejoras. 58
7.7. Mejora a la configuración de la red 62
7.8. Aplicación de series adicionales para mejorar la predicción. 66
7.9. Definición de la combinación de Variables definitiva. 68
7.10. Análisis del costo computacional. 70
7.11. Búsqueda del modelo principal. 73
7.12. Modelo definitivo. 77
7.13. Evaluación de la Hipótesis 79
7.14. Conclusiones. 101
8. Anexo. 104
8.1. El código fuente 104
8.1.1. Variables y datos globales. 105
8.1.2. Carga de Series desde archivos. 107
8.1.3. Preprocesamiento de las Series para entrenar. 107
8.1.4. Creación de la Red 112
8.1.5. Armado de predicción. 116
8.1.6. Comparación de predicción con resultados reales. 117
9. Bibliografía. 118

Tabla de Gráficos.

Gráfico 1 Ejemplo con la acción de Grupo Financiero Galicia y los indicadores de Momento más Medias Móviles para los últimos 50 días. 11
Gráfico 2 Ejemplo con la acción de Tenaris en New York y los indicadores de Momento más Medias Móviles para los últimos 50 días. 12
Gráfico 3 Ejemplo de variaciones de cotizaciones intradiarias. 16
Gráfico 4 Interpolación. 17
Gráfico 5 Extrapolación. 17
Gráfico 6 Esquema de una neurona biológica. 20
Gráfico 7 Representación esquemática de una red neuronal matemática. 21
Gráfico 8 Esquema de una neurona artificial. 22
Gráfico 9 Funciones de activación. 23
Gráfico 10 Modelo multicapa de neuronas. 24
Gráfico 11 Modelo multicapa de Neuronas. 25
Gráfico 12 Mínimo de una curva. 28
Gráfico 13 Gráfico de una superficie tridimensional. 29
Gráfico 14 Localización de mínimos locales. 30
Gráfico 15 Tamaño adecuado del paso. 30
Gráfico 16 Pasos largos vs pequeños. 31
Gráfico 17 Esquema de red neuronal recurrente. 32
Gráfico 18 Representación de celda LSTM. 33
Gráfico 19 Representación de celda GRU. 34
Gráfico 20 Curvas de adopción de lenguajes de programación. 36
Gráfico 21 Representación esquemática del modelo de entradas múltiples. 37
Gráfico 22 Evolución del PBI de EEUU. 39
Gráfico 23 Interacciones de las Macroeconomía. 43
Gráfico 24 Evolución del PBI y del índice Merval. 44
Gráfico 25 Esquema secuencial de primera red. 56
Gráfico 26 Curvas Reales, predicha y medias móviles. 57
Gráfico 27 Captura de consola de salida durante el entrenamiento. 59
Gráfico 28 Esquema de red de múltiples entradas utilizada. 60
Gráfico 29 Esquema de red de 5 entradas. 61
Gráfico 30 Esquema de red de 6 entradas. 64
Gráfico 31 Curvas de aciertos y errores. 65
Gráfico 32 Gráfico de costo computacional en función del tamaño de ventana. 71
Gráfico 33 Resultados en función del tamaño de ventana. 72
Gráfico 34 Curva de resultados promedios obtenidos en función de la ventana. 75

Gráfico 35 Desviación estándar de los resultados en función de la ventana. 76
Gráfico 36 Comparativa de predicción promedio vs Variación porcentual del Tipo de Cambio. 81
Gráfico 37 Curvas comparativas de promedios de aciertos mensuales vs la variación porcentual de tasa. 82
Gráfico 38 Curva comparativa entre los promedios mensuales de aciertos y la Base Monetaria. .. 83
Gráfico 39 Comparativa entre la evolución de la predicción promedio y el porcentaje de variación del Riesgo País. 84
Gráfico 40 Curvas comparativas entre el diferencial mensual de las predicciones promedio y el contado con liquidación. 87
Gráfico 41 Curva comparativa entre el diferencial mensual de la predicción promedio y el riesgo país. 88
Gráfico 42 Curva comparativa entre la evolución mensual de la predicción promedio y la variación porcentual de los depósitos de privados. 89
Gráfico 43 Correlaciones para cada acción con el porcentaje de variación del T.C. 91
Gráfico 44 Correlación entre los porcentajes de aciertos mes a mes y el riego País para TXAR.BA. 92
Gráfico 45 Correlación entre los porcentajes de aciertos mes a mes y el porcentaje de variación de la Base Monetaria para IRSA.BA. 93
Gráfico 46 Correlación entre los porcentajes de aciertos mes a mes y el riesgo País para TGUS2.BA. 94
Gráfico 47 Correlación entre los porcentajes de aciertos mes a mes y la base monetaria para PAMP.BA. 95
Gráfico 48 Correlación entre los porcentajes de aciertos mes a mes y el contado con liquidación para PAMP.BA. 95
Gráfico 49 Correlación entre los porcentajes de aciertos mes a mes y la variación en porcentaje del Contado con Liquidación para ALUA.BA. 96
Gráfico 50 Correlación entre los porcentajes de aciertos mes a mes y la base monetaria para CRES.BA. 97
Gráfico 51 Correlación entre los porcentajes de aciertos mes a mes y la variación porcentual de la Tasa para CEPU.BA. 98
Gráfico 52 Correlación entre los porcentajes de aciertos mes a mes y la variación porcentual del Riesgo País para GGAL.BA. 99
Gráfico 53 Correlación entre los porcentajes de aciertos mes a mes y la variación porcentual de la tasa para YPFD.BA. 100
Gráfico 54 Correlación entre los porcentajes de aciertos mes a mes y la variación porcentual del Tipo de Cambio para EDN.BA. 101
Gráfico 55 Comparativa entre el porcentaje de predicción promedio mensual y la variación porcentual del Tipo de Cambio. 103
Gráfico 56 Comparativa entre el diferencial mensual de la predicción y el Contado con Liquidación. 103
Gráfico 57 Diagrama de flujo del código 105
Gráfico 58 Extracto de código fuente para definiciones globales e inicializaciones 106
Gráfico 59 Extracto de código fuente para carga de series desde archivos 107

Gráfico 60 Extracto de código fuente para escalamientos 108
Gráfico 61 Extracto de código fuente para preprocesamiento..... 110
Gráfico 62 Extracto de código fuente para la creación de la red..... 113
Gráfico 63 Extracto de código fuente para la predicción..... 116
Gráfico 64 Extracto de código fuente para la evaluación de los resultados..... 117

Índice de Tablas

Tabla 1 Formación de las Tuplas de entrenamiento 54
Tabla 2 Resultados alcanzados para diferentes ventanas 57
Tabla 3 Lista de acciones evaluadas 58
Tabla 4 Resultados obtenidos en diferentes corridas 60
Tabla 5 Resultados obtenidos en diferentes corridas 62
Tabla 6 Resultados obtenidos variando el LR y la ventana 63
Tabla 7 Resultados de modelo de 6 entradas 64
Tabla 8 Resultados para modelos específicos por acción 68
Tabla 9 Resultados incrementando las iteraciones 69
Tabla 10 Resultados mejor modelo para Ventana de 10 Cotizaciones 73
Tabla 11 Resultados mejor modelo para Ventana de 20 Cotizaciones 74
Tabla 12 Resultados mejor modelo para Ventana de 35 Cotizaciones 74
Tabla 13 Resultados mejor modelo para Ventana de 40 Cotizaciones 74
Tabla 14 Resultados mejor modelo para Ventana de 60 Cotizaciones 75
Tabla 15 Mejor modelo encontrado 77
Tabla 16 Casos utilizados para el mejor modelo 78
Tabla 17 Resultados de las predicciones mes a mes 79
Tabla 18 Promedios mes a mes de predicciones 79
Tabla 19 Correlaciones obtenidas para los promedios mes a mes 80
Tabla 20 Análisis de valores correlacionados con el porcentaje de variación del TC 81
Tabla 21 Comparativa entre los aciertos promedio mensuales y la variación porcentual de la tasa82
Tabla 22 Comparación de los promedios de aciertos mensuales y la evolución de la base monetaria 83
Tabla 23 Promedios de aciertos mes a mes y diferenciales mes a mes, Fuente: Elaboración Propia. 85
Tabla 24 Correlaciones halladas para los diferenciales en porcentaje de los promedios de aciertos mes a mes 86
Tabla 25 Correlación entre los diferenciales de los promedios de aciertos mes a mes y el Contado con Liquidación 86
Tabla 26 Correlación entre los diferenciales de los promedios de aciertos mes a mes y el Riesgo País 87
Tabla 27 Correlación entre los diferenciales de los promedios de aciertos mes a mes y la variación porcentual de los depósitos de privados 88
Tabla 28 Resumen de correlaciones halladas 90
Tabla 29 Correlaciones acción por acción versus la variación porcentual del Tipo de Cambio 90
Tabla 30 Resumen de correlaciones halladas acción por acción 91
Tabla 31 Resumen de correlaciones halladas para CEPU.BA 98
Tabla 32 Resumen de correlaciones halladas 102

1. Abstract.

La evolución de los precios de un activo bursátil tiene descontados factores fundamentales, macroeconómicos y tendenciales del mercado, todas estas variables mantienen relaciones entre sí que pueden ser utilizadas para establecer la evolución esperada del valor del activo.

El presente trabajo comparte el resultado de la búsqueda de un marco de condiciones y temporal concreto de aplicación de redes neuronales a la predicción de la evolución de un activo bursátil dado. Basándose en una investigación práctica desarrollada para poner a prueba la hipótesis sobre el grado de predicción que una red neuronal puede establecer en la evolución de los precios tomando la relación que estos pueden tener con otras variables macroeconómicas.

Entendiendo que esa predicción no es posible en cualquier escenario, el presente trabajo se centra en delimitar condiciones concretas de aplicación para la utilización de la red neuronal en la predicción y para establecer un intervalo de confianza temporal para la misma.

2. Presentación y antecedente del tema de investigación.

Existen muchos trabajos y modelos matemáticos que tienen como finalidad aportar en la predicción del valor de un activo bursátil.

Muchos de ellos abordan la problemática desde el punto de vista estadístico, otros tantos utilizan indicadores matemáticos que luego de operar una sección de la serie de precios, devolver un indicador cuyo valor podría generar algún nivel de interpretación en orden de predecir la evolución esperada.

Son ejemplo de estos indicadores casos como las Medias Móviles, Rate of Change, Indicador de momento y muchos otros más, todos y cada uno de estos indicadores tienen un mecanismo de interpretación para definir la recomendación implícita en el mismo.

Gráfico 1 Ejemplo con la acción de Grupo Financiero Galicia y los indicadores de Momento más Medias Móviles para los últimos 50 días.

Fuente: Yahoo Finanzas

En investigaciones previas desarrolladas por el autor, teniendo estas como finalidad encontrar un marco de aplicación concreto para un amplio número de estos indicadores y sus diferentes configuraciones, no se ha podido establecer un grado de certeza y predictibilidad aceptable para los mismos.

Paralelamente una red neuronal es, en definitiva, una solución matemática que puede generar una extrapolación eficiente a una función multi – variable, por ello podría pensarse una función que tenga como entrada un conjunto de variables macroeconómicas junto con el precio de la acción a lo largo de un período de tiempo y como salida la evolución inmediata del precio de la acción, la red se entrena con este conjunto de datos para luego ser puesta a prueba y realimentada con la evolución subsiguiente.

Sea cual sea el método por el cual se quiera aproximar el problema siempre habrá que enfrentar el hecho de que se está tratando de predecir el comportamiento de un sistema complejo del cual no se conocen todas las variables intervinientes, con lo cual no parece ser esperable encontrar un mecanismo de predicción global que se adecúe a todos los casos.

En el caso particular de la aplicación de una red neuronal a la resolución de este tipo de problemas, puede aparecer un sesgo esperado por el tipo de solución y el mismo radica en que invariablemente la red maximizará su ajuste al conjunto de datos utilizados para su entrenamiento, pero eso no necesariamente significa que la evolución futura de la realidad sea coincidente con dicho ajuste.

Gráfico 2 Ejemplo con la acción de Tenaris en New York y los indicadores de Momento más Medias Móviles para los últimos 50 días.

Fuente: Yahoo Finanzas.

El gráfico precedente muestra claramente, en opinión del autor, que no hay mecanismo global que pueda predecir la evolución de los precios de un activo dado que la caída que observamos el día 8 de marzo de 2020, que fue generalizada, no es atribuible a ninguna de las variables que seguramente habríamos seleccionado poco tiempo antes para correlacionar con el activo en cuestión.

Pero la imposibilidad de predecir de forma global y en cualquier momento no implica que no existan marcos en los cuales se pueda lograr un nivel de predicción.

El foco del presente trabajo será ejecutar una investigación para buscar relaciones entre la evolución de variables de la macroeconomía y la capacidad de predicción de un modelo basado en redes neuronales.

3. Objetivos generales y específicos.

El objetivo general del trabajo es analizar la correlación que existe entre la evolución de diferentes variables o indicadores de la macroeconomía y la capacidad de predicción alcanzada por una red neuronal para los precios bursátiles de un conjunto de acciones argentina.

Objetivos específicos:

- Establecer un conjunto de variables macroeconómicas y escoger las series de precios de las acciones que se utilizarán para armar un conjunto de datos y entrenar una red neuronal.
- Establecer el tipo de red neuronal a ser utilizado considerando la capacidad computacional máxima disponible.
- Iterar las pruebas para maximizar los resultados.
- Analizar cualitativamente los resultados.
- Establecer el grado de correlación y un marco confianza en las predicciones.

4. Metodología.

La metodología propuesta para el trabajo será la siguiente:

Fase 0: Selección de los activos bursátiles con los que se trabajará.

Fase 1: Evaluación de las opciones disponibles para seleccionar el conjunto de datos a ser utilizado para el entrenamiento de la red neuronal.

Tales variables pueden ser diferentes tipos de cambio, indicadores de actividad, base monetaria, índices de desocupación, expectativa inflacionaria, precio del barril de petróleo, producción en cantidad de barriles de petróleo, producción de gas, nivel de ocupación de la capacidad instalada industrial y por supuesto la evolución del precio del o de los activos bursátiles seleccionados.

Fase 2: Evaluación de los diferentes tipos de redes neuronales disponibles, evaluación de sus características y selección del mecanismo considerado más adecuado para este tipo de problemas.

Fase 3: Planificación y definición de la cantidad de redes que se crearán, las estrategias a seguir y los objetivos a alcanzar.

Fase 4: Entrenamiento de las redes y prueba de resultados.

Fase 5: Evaluación de las correlaciones entre las predicciones y las variables macroeconómicas seleccionadas.

5. Limitaciones y Restricciones.

El trabajo se limitará a un conjunto de 10 acciones de empresas argentinas pertenecientes al panel Merval 25 cuyas cotizaciones se tomarán de la Bolsa de Comercio de Buenos Aires.

El objetivo del trabajo es evaluar en qué medida influye el contorno macroeconómico en el grado de predicción, no es la predicción en sí mismo y el alcance no es global en el tiempo.

6. Marco Teórico

6.1. Conceptos iniciales

6.1.1. Aproximación de funciones matemáticas.

Una función matemática es una relación que se establece entre dos conjuntos, a través de la cual a cada elemento del primer conjunto se le asigna un único elemento del segundo conjunto o ninguno. Al conjunto inicial o conjunto de partida también se lo llama dominio; al conjunto final o conjunto de llegada, en tanto, se lo puede denominar codominio.

Esta relación puede tomar como dominio un conjunto de números, por ejemplo, los naturales y como codominio la consecuencia de realizar un cálculo sobre el número perteneciente al dominio.

Podemos mencionar como ejemplo $f(x) = x^2$, con x perteneciente al conjunto de números naturales (1, 2, 3, ….,∞) siendo f(x) para este ejemplo (1, 4, 9, …., ∞)

Existen casos en los que esta relación puede llegar a surgir como consecuencia de establecer mediciones sucesivas de un determinado evento, el cual podría ser por ejemplo la temperatura en un determinado lugar a lo largo de las horas de un día o el precio de una acción en el mercado bursátil. En estos casos no es posible, en principio, establecer un mecanismo de cálculo concreto que permita representar esa función.

Siguiendo este razonamiento, si tomamos la evolución del precio de cierre de una acción a lo largo de los días solo tenemos un conjunto de datos que podemos llegar a representar gráficamente y que cumplen con la definición de función establecida.

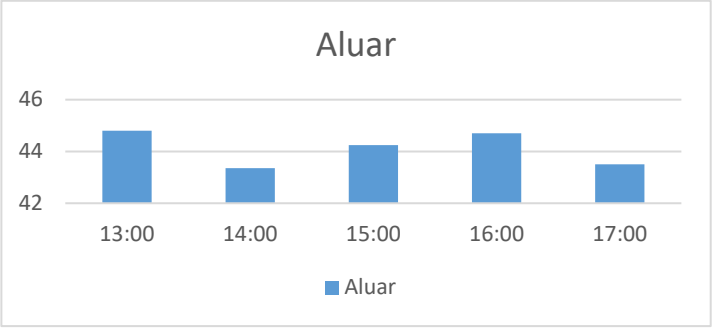

Gráfico 3 Ejemplo de variaciones de cotizaciones intradiarias.

Fuente: Puentenet.com

En cualquier caso, el ejemplo mencionado en el gráfico anterior no deja de ser un conjunto de números discretos tomados cada un determinado lapso. Pueden existir, y de hecho en este caso existen, valores intermedios que descartaremos para continuar con el ejemplo. En cualquier caso, no es posible definir un cálculo matemático que pueda expresar con exactitud la función de este ejemplo.

Para todos estos casos en los que, o bien el método de cálculo para la función es conocido y muy complejo, o sencillamente el método de cálculo no es conocido, como el ejemplo anterior, existe la posibilidad de implementar algún mecanismo de aproximación matemática.

6.1.2. Interpolación de funciones matemáticas

La interpolación matemática de funciones es un proceso que desde mediciones realizadas sobre algún fenómeno o conjunto de datos (precipitación, temperatura o elevación, precios de acciones, etc.) en determinados lugares, para hacer una predicción sobre un fenómeno en otros lugares donde no se han realizado mediciones.

En el subcampo matemático del análisis numérico, se denomina interpolación a obtención de nuevos puntos partiendo del conocimiento de un conjunto de puntos.

Otro problema estrechamente ligado con el de la interpolación es la aproximación de una función complicada por una más simple.

Existen muchos métodos matemáticos de interpolación, como ser los polinómicos. En todos los casos, estos mecanismos permiten intentar aproximar los puntos que se encuentran dentro de conjunto de valores tomados como punto de partida.

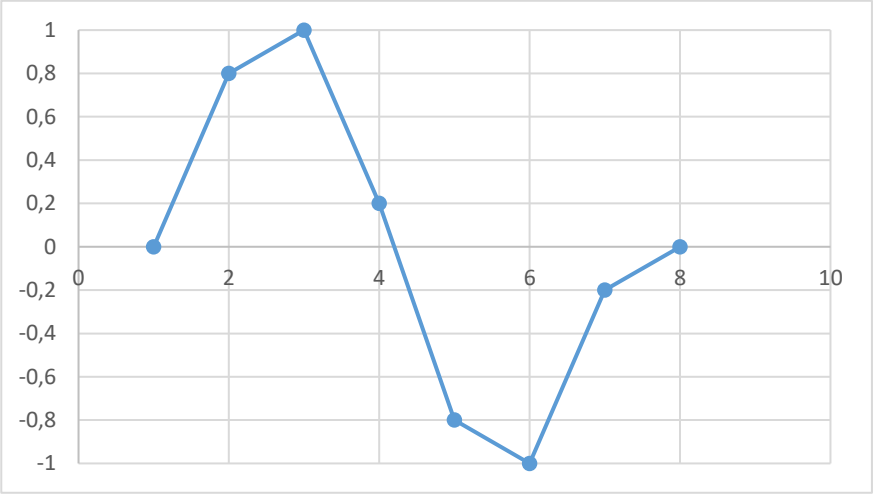

Gráfico 4 Interpolación.

Fuente: Elaboración propia.

Es justamente esto un punto en contra a la hora de intentar utilizar métodos de interpolación con la intención de pronosticar movimientos de precios de una acción, dado que se partiría de un conjunto de datos para tratar de predecir un valor que se encuentra fuera de la muestra.

6.1.2. Extrapolación de funciones matemáticas.

Para el caso que nos convoca es más aplicable la extrapolación, que a partir de un conjunto de datos trata de predecir un nuevo valor, pero esta vez por fuera del intervalo.

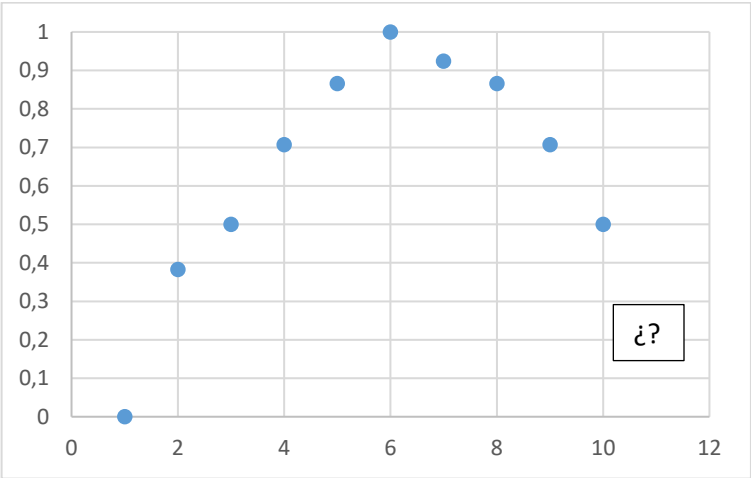

Gráfico 5 Extrapolación.

Fuente: Elaboración propia

Todos los métodos conocidos de interpolación o extrapolación no parecen ser adecuados para la empresa de utilizarlos para lograr una predicción útil de la evolución de los precios de un activo bursátil.

Pero cada vez tienen mayor aplicación y utilización los algoritmos de machine learning, los cuales en el fondo son un mecanismo altamente sofisticado de extrapolación y es por ello que hemos tratado este concepto.

6.1.3. Machine Learning

Machine Learning es un conjunto de técnicas algorítmicas que permiten que una computadora aprenda de los datos. Es decir, el objetivo es permitir a un computador aprender de un conjunto de datos sin la necesidad de tener que programarle específicamente ese conocimiento.

Son algoritmos que imitan el sistema de aprendizaje humano, en el cual existe una etapa de aprendizaje o entrenamiento en la que se somete al sistema a una serie de ejemplos con sus respectivos resultados esperados y esta colección de ejemplos va condicionando la respuesta futura del sistema.

La característica de no necesitar que se programen los detalles que deben aprenderse, no solo es extremadamente útil para simplificar el proceso de aprendizaje, sino que además es indispensable para aquellos casos en los que ciertamente no se conoce al detalle el comportamiento que se desea programar.

Por ejemplo, para el caso de este trabajo, ciertamente no se conoce un método algorítmico que pueda predecir los movimientos de los precios de una acción y entonces el machine learning en este caso cobra particular relevancia dado la imposibilidad de otras opciones.

6.1.3.1. Campo de aplicación del machine learning.

Mas allá de la potencial universalidad de la aplicación de las técnica de machine learning, debe destacarse la capacidad de aplicar las mismas a aquellos campos que se muestran elusivos para poder desarrollar programas tradicionales que automaticen respuesta antes las potenciales entradas, es decir, estas técnicas son enormemente útiles y eficientes en los casos en los que quien se embarque en la tarea de crear una pieza de software que pueda operar en la disciplina no tenga un nivel de conocimiento completo sobre la materia de la solución, esta idea, de todos modos también tiene limitaciones dado

que la habilidad del operador para seleccionar y presentar los casos de entrenamiento es relevante en los resultados que se obtendrán.

6.1.3.2. Tipos de estrategias de machine learning.

(Manchado, 2018) Existen diferentes modos de abordar el proceso de aprendizaje tendiente al armado de un mecanismo capaz de dar una respuesta a ciertos estímulos en función de cómo las experiencias previas lo han condicionado.

a. Aprendizaje no supervisado.

Consiste en aquellos casos en los que el conjunto de entrenamiento solo incluye una colección de entradas posibles, pero no tiene para estas entradas la definición de las respuestas esperadas.

b. Aprendizaje supervisado.

En el caso del aprendizaje supervisado, el entrenamiento se lleva a cabo con el armado de un set de datos que cuenta con un conjunto de entradas a las que se le asocian las respuestas esperadas. En estos casos el entrenamiento fuerza el ajuste a estos casos de ejemplo.

Suele ser el caso más utilizado.

Particularmente, las redes neuronales que utilizaremos en este trabajo se basan en esta estrategia de entrenamiento.

c. Aprendizaje semi-supervisado.

Este caso es una combinación de los anteriores, que combina set de datos que pueden o no tener asociadas respuestas esperadas para el entrenamiento.

d. Aprendizaje por refuerzo

Este es un caso diferente a los anteriores, que se inspira en la psicología conductista y lleva al algoritmo entrenado a preferir un tipo de respuesta por sobre otra en función de lograr maximizar una recompensa o minimizar pérdidas. Este es el mecanismo usado para el aprendizaje competitivo, es decir las redes que aprenden a por ejemplo a jugar un video juego.

6.1.4. Redes Neuronales Artificiales

6.1.4.1. Definición y funcionamiento

Una red neuronal artificial es un modelo matemático inspirado en el funcionamiento del cerebro humano. Está formado por un conjunto de nodos conocidos como neuronas artificiales que están conectadas y transmiten señales entre sí. Estas señales se transmiten desde la entrada hasta generar una salida.

En el caso del cerebro humano (factor de inspiración para el concepto de redes neuronales) es un enorme conjunto de células llamadas neuronas, las cuales se encuentran conectadas entre sí y que se transmiten impulsos eléctricos a modo de señales, cada célula procesa los impulsos recibidos y los envía en alguna medida a sus células vecinas.

Cada neurona cerebral está compuesta de cuatro elementos: las dendritas que son las que reciben los impulsos de entrada, el soma que procesa estos estímulos recibidos, el axón que tiene como función preparar esta información para que pueda ser recibida por las neuronas subsiguientes y la sinapsis que son las conexiones con las otras neuronas.

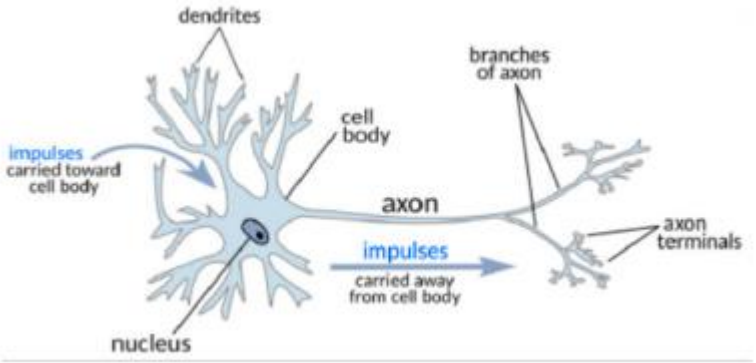

Gráfico 6 Esquema de una neurona biológica.

Fuente: (Manchado, 2018)

La red recibe una serie de valores de entrada y cada una de estas entradas llega a un nodo llamado neurona. Las neuronas de la red están a su vez agrupadas en capas que forman la red neuronal. Cada una de las neuronas de la red posee a su vez un peso, un valor numérico, con el que modifica la entrada recibida. Los nuevos valores obtenidos salen de las neuronas y continúan su camino por la red. Las neuronas se encuentran interconectadas y los diferentes pesos establecen la intensidad con la que la señal se debe propagar en cada caso en la dirección de la conexión administrada por dicho peso (Rashid, 2017).

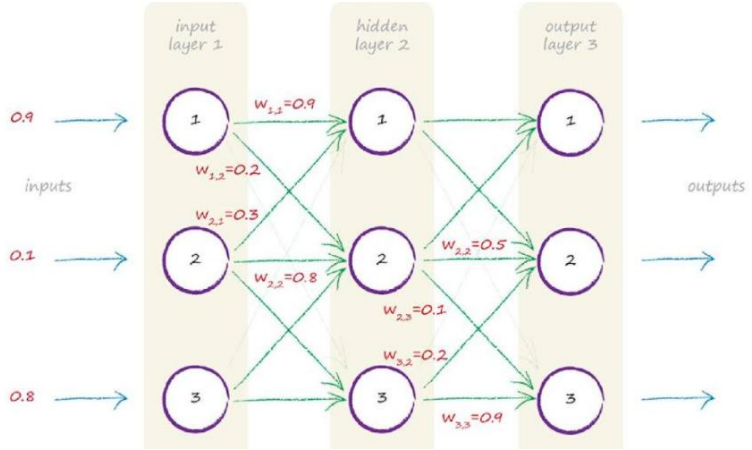

Gráfico 7 Representación esquemática de una red neuronal matemática.

Fuente: Make your own neural networks (Tarik Rashid)

Cada neurona o nodo de la red tiene un conjunto de entradas desde donde recibe señales de estímulo y un mecanismo para establecer el grado de excitación ante el estímulo recibido.

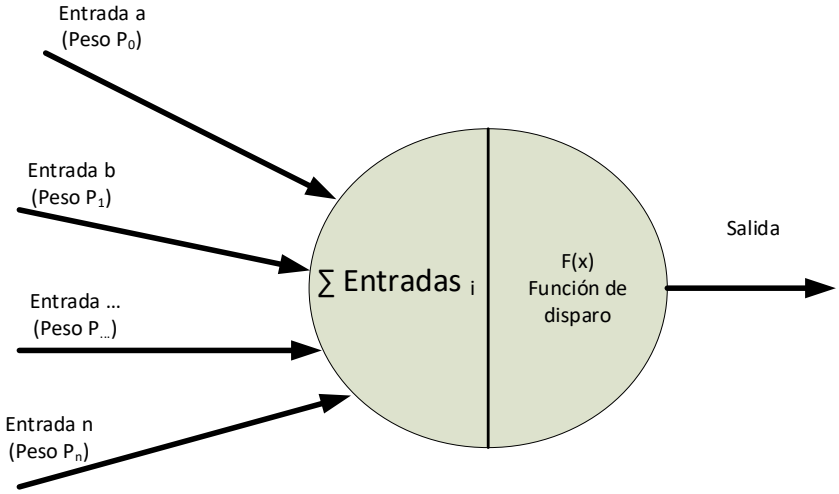

Gráfico 8 Esquema de una neurona artificial.

Fuente: Elaboración Propia

El mecanismo de decisión para establecer el grado de sensibilidad al estímulo recibido suele representarse por una función de disparo que define la forma en la que se comportará la sensibilidad de la neurona al conjunto de estímulos recibidos, dejándolo pasar o no para proyectar un determinado valor sobre las siguientes neuronas en la interconexión establecida.

Existen diferentes funciones que pueden llegar a utilizarse para implementar el disparo de una neurona y la prevalencia de una sobre otra depende en muchos casos del tipo de problema que se espera resolver con la red neuronal.

	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	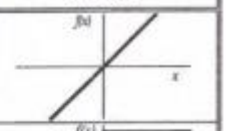
Escalón	$y = sign(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	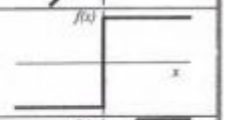
Lineal a tramos	$y = \begin{cases} -1, & si\ x < -l \\ x, & si\ +l \le x \le -l \\ +1, & si\ x > +l \end{cases}$	$[-1, +1]$	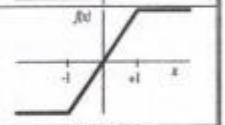
Sigmoidea	$y = \frac{1}{1+e^{-x}}$ $y = tgh(x)$	$[0, +1]$ $[-1, +1]$	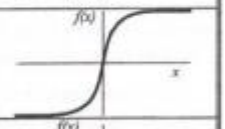
Gaussiana	$y = Ae^{-Bx^2}$	$[0,+1]$	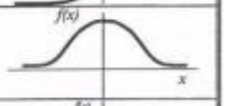
Sinusoidal	$y = A\,\mathrm{sen}(\alpha x + \varphi)$	$[-1,+1]$	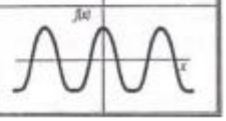

Gráfico 9 Funciones de activación.

Fuente: (Manchado, 2018)

Cada neurona tiene, en definitiva, un comportamiento simple, pero una enorme cantidad de neuronas interconectadas forman una red compleja, justamente es importante aclarar que parte de tal complejidad se logra debido a que los vínculos entre las diferentes neuronas se regulan con pesos específicos particulares para cada interrelación.

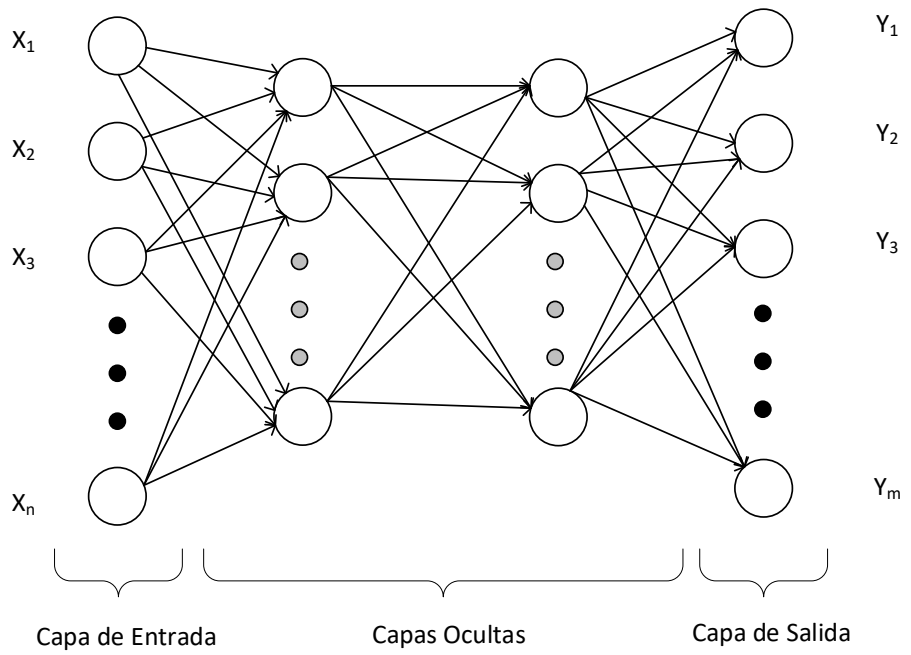

Gráfico 10 Modelo multicapa de neuronas.

Fuente: Elaboración propia

6.1.4.2. Formulación del comportamiento de una red neuronal.

Para establecer la formulación matemática de lo expresado a una neurona hasta ahora llegamos a lo siguiente:

$$u = w_0 + \sum_{i=1}^{n} w_i . x_i$$

Ecuación 1

$$y = F(u + b)$$

Ecuación 2

Tomando como base la figura que representa una neurona biológica, podemos hacer una analogía con los conceptos vistos más abajo. En la neurona matemática postulada, los pesos (w_i) de entrada representan a las dendritas (o conexiones entrantes con otras neuronas), las x_i son las entradas propiamente dichas, es decir la señal que arriba de otras neuronas, la sumatoria establece una analogía con el axón, y aplicando la función de activación obtenemos la salida resultante que esta neurona en particular propagará en las entradas de las neuronas conectadas con esta a su salida.

La sucesiva combinatoria de neuronas proyectando sobre sus sucesoras en la matriz de interconexiones el producto de su grado de activación en función de la entrada recibida termina impactando en un determinado nivel de salida.

6.1.4.3. Perceptron

La neurona que hemos definido tiene su origen en el trabajo de Frank Rosenblatt, quien en el año 1958 desarrollo un modelo simple de neurona tratando de replicar el funcionamiento del cerebro humano. Este modelo se mostró útil para resolver problemas de clasificación y para la implementación de funciones lógicas como AND y OR pero no para implementar la función lógica XOR.

Como mejora al concepto original de perceptrón, apareció el perceptrón multicapa, el cual es el modelo de red neuronal simple explicado hasta ahora. (Alcalá Nalvaiz, 2018), en el se combinan una capa de entrada de N neuronas, una de salida con M neuronas y una capa intermedia oculta, el objetivo permanece intacto, es lograr una correspondencia entre un conjunto de entradas y un conjunto de salidas.

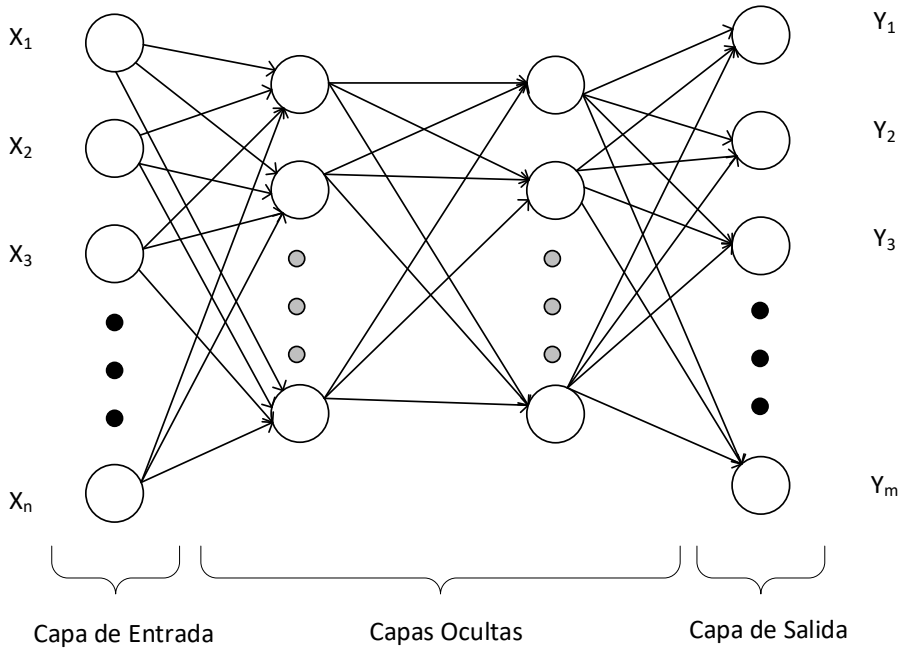

Gráfico 11 Modelo multicapa de Neuronas.

Fuente: Elaboración propia

6.1.4.4. Entrenamiento de la red neuronal.

Es precisamente de este esquema en el cual se establecen cadenas de neuronas que proyectan sus grados de activación sobre pesos de entradas de sus sucesoras que surge la idea de aprendizaje artificial o entrenamiento.

En definitiva, el aprendizaje artificial consiste en someter a la red a un conjunto de entradas y sus salidas esperadas, para que de esta forma sea posible (mediante un mecanismo que trataremos más adelante) calibrar los pesos sucesivos que generan el mejor ajuste de la red al set de datos de entrenamiento recibido.

Las etapas de este proceso son:

- **Inicialización de la red:** Al comienzo del proceso de aprendizaje, se crean y dimensionan los elementos que contendrán la red (Matrices o tensores) y se los inicializa con valores aleatorios para sus pesos.
- **Propagación hacia adelante:** Comienza a introducirse la información de los casos desde la entrada hacia la salida pasando por las funciones de activación de las neuronas interconectadas. En cada instante de tiempo se trata de reconfigurar los pesos de modo de reducir el error.
- **Asignación del error:** al alcanzar un valor de error menor que la cota preestablecida, el error no decrece lo suficiente o se alcanzó el número máximo de iteraciones, el algoritmo se detiene, en otro caso pasa al próximo paso de retro propagación.
- **Retro propagación:** El error obtenido es propagado desde la salida hacia la entrada a través de la red, con el objeto de refinar los pesos.
- **Ajuste:** Se perfeccionan los pesos a través del descenso del gradiente.

Para ir generando el mejor ajuste posible se aplica una técnica llamada retro propagación o propagación hacia atrás (backpropagation en inglés), esta técnica consiste en aplicar a la red las entradas, las cuales se propagan y generan una determinada salida, esta salida tendrá un error o diferencia con el valor esperado.

Las salidas se propagan hacia atrás, a partir de la capa de salida, para que las diferentes capas (de fin a principio) puedan ajustar los pesos de vinculación entre neuronas de modo de mejorar el ajuste de la salida. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución relativa al error total.

Este proceso es relevante debido que, a medida que se entrena la red, es decir se la somete a conjuntos de entradas con sus salidas esperadas, las neuronas de las capas intermedias van configurando sus pesos de interconexión generando una auto organización de tal modo que las distintas neuronas aprenden a reconocer distintas características del espacio total de entrada.

Una vez finalizado el entrenamiento, al someter a la red a un patrón arbitrario de entrada que contenga ruido o que esté incompleto, las neuronas de la capa oculta de la red responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a aquella característica que las neuronas individuales hayan aprendido a reconocer durante su entrenamiento.

6.1.4.5. Descenso del gradiente.

El descenso de gradiente (Rashid, 2017) es un algoritmo que estima numéricamente dónde una función genera sus valores más bajos. Eso significa que encuentra mínimos locales, este algoritmo no utiliza el método convencional utilizado para encontrar máximos y mínimos en análisis matemático (consistente es analizar los puntos en los que se vuelve 0 la derivada).

El descenso de gradiente aproxima la solución con números. Además, todo lo que necesita para ejecutarse es la salida numérica de una función, no requiere ninguna fórmula.

Vale la pena enfatizar esta distinción porque es lo que hace que este método resulte útil. Si tuviéramos una fórmula simple como $f(x) = x^2 - 4x$, en este caso el cálculo de la derivada y la búsqueda de máximos y mínimos de forma tradicional es posible dado la sencillez de la función llegando a que el mínimo de la función está en x=2, ó se puede aproximar mediante el algoritmo y llegar a un valor similar al siguiente: x≈1,99999967, podríamos tomar entonces a esta estrategia como válida.

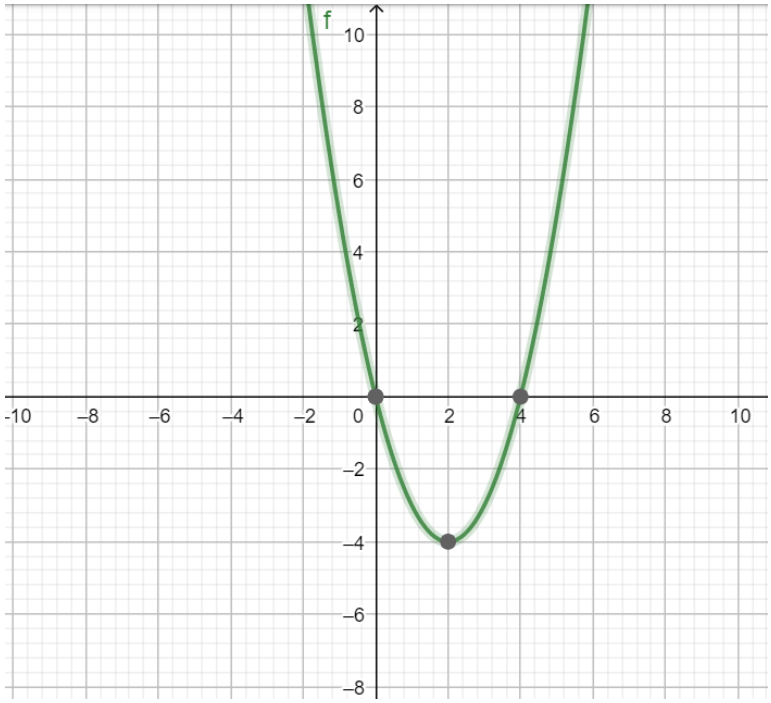

Gráfico 12 Mínimo de una curva.

Fuente: calculadora gráfica https://www.geogebra.org/graphing?lang=es-AR

En los casos en los que no se posee la fórmula de la función y esta no puede derivarse con sencillez este método deja de ser aplicable, sobre todo en los casos en los que la función crece en variables y en complejidad, este caso es cuando una solución aproximada es valiosa y el descenso de gradiente puede darnos estas estimaciones sin importar cuán elaborada sea nuestra función.

La manera en la que el descenso de gradiente logra encontrar el mínimo de funciones es más sencilla de ver considerando tres dimensiones.

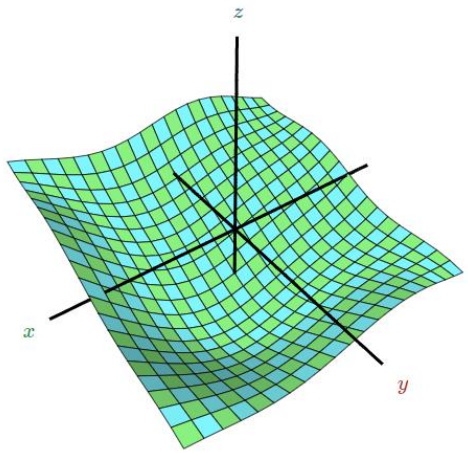

Gráfico 13 Gráfico de una superficie tridimensional.

Fuente: Imágenes de google

Partiendo de una función f(x, y) que defina por ejemplo un terreno montañoso, y considerando que el gradiente evaluado en cualquier punto de la misma representa la dirección del ascenso más pronunciado, podríamos utilizar esta idea para encontrar los mínimos de la función.

Partimos de un punto aleatorio y nos movemos en la dirección indicada por el negativo del gradiente, y de esa manera ir en la dirección del descenso más pronunciado.

Si comenzamos en un punto x_n y nos movemos una distancia positiva α en la dirección del gradiente negativo, el nuevo punto se verá así:

$$x_{n+1} = x_n - \nabla f(x_n)$$

Ecuación 3

Este concepto se itera encontrando mejoras sucesivas hasta encontrar un mínimo local.

La limitación de este mecanismo radica en que encuentra mínimos locales y que el punto de partida aleatorio puede generar resultados diferentes en cada corrida. Si el arranque aleatorio cae cerca de un mínimo local ineficiente, se corre el riesgo de no poder salir de ese pozo localizado.

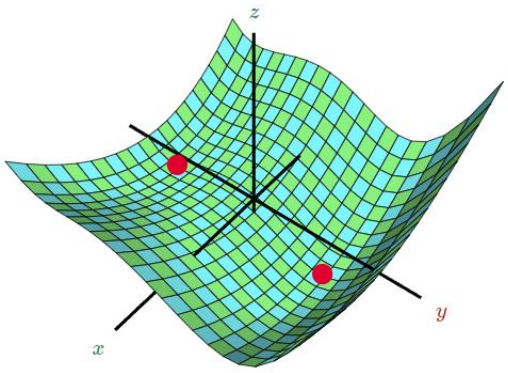

Gráfico 14 Localización de mínimos locales.

Fuente: imágenes de google

Como el tamaño del salto es un parámetro definible y variable, es importante escogerlo con cuidado, en general si este valor es grande, puede generar como consecuencia el pasar por alto la zona en la cual se encuentra el mínimo.

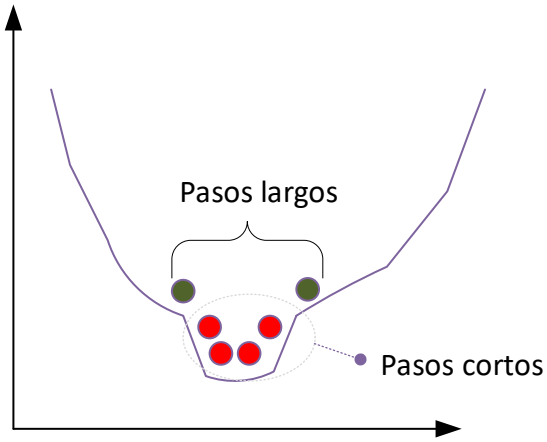

Gráfico 15 Tamaño adecuado del paso.

Fuente: Elaboración propia

En contrapartida, valores muy cortos para el salto, requerirán de mayor costo computacional para lograr avanzar.

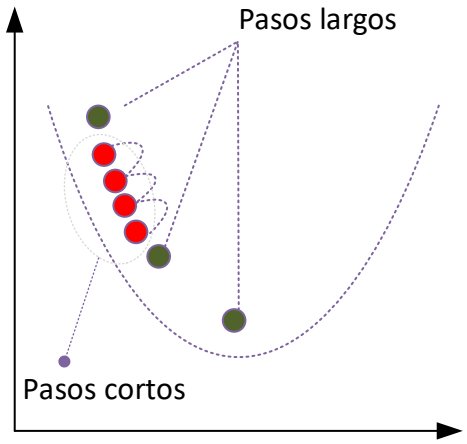

Gráfico 16 Pasos largos vs pequeños.

Fuente: Elaboración Propia

El tamaño del salto o Learning rate, debe ser buscado entonces de forma empírica.

6.1.4.6. Redes Neuronales Recurrentes.

Hasta ahora hemos trabajado con un concepto de red neuronal en el cual los estímulos tienen un tráfico en una única dirección, desde la entrada hacia la salida, las interconexiones entre las neuronas forman una jerarquía que parte desde la entrada y a la salida de cada neurona se la vincula con la entrada de otra, esto se repite de forma sucesiva hasta la salida final del sistema.

En 1986 fue presentado un nuevo tipo de red neuronal cuya característica distintiva radicaba en que la propia salida era reinyectada dentro de la red para generar retroalimentación, en definitiva para cada momento t una neurona de una red recurrente recibe en su entrada x_t y adicionalmente recibe y_{t-1} (es decir la salida del paso anterior) (David E. Rumelhart, 1986)

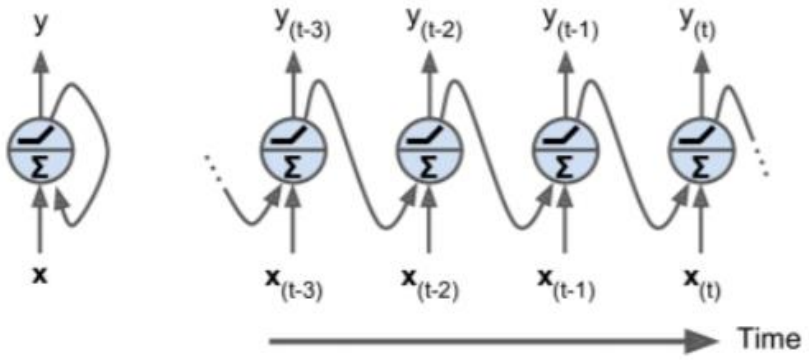

Gráfico 17 Esquema de red neuronal recurrente.

Fuente: (Manchado, 2018)

Se pueden definir una capa con neuronas que reciba la entrada actual y adicionalmente la salida de la muestra previa, esto hace que la red tenga que definir dos conjuntos de pesos para calibrar la salida (los pesos que regulan las entradas propiamente dichas y los pesos que regulan la retroalimentación).

De esta manera se incorpora en la red el concepto de memoria, los estímulos pasados tienen un grado de influencia sobre los actuales y estos sobre los futuros.

Este tipo de red neuronal resultó ser muy eficiente para la predicción de series temporales.

6.1.4.7. Celda LSTM

La celda LSTM es una variante de Red Neuronal Recurrente, fue propuesta en 1997 por Sepp Hochreiter y Jürgen Schmidhuber (Sepp Hochreiter, 1997).

Esta celda incorpora el concepto de memoria a corto y largo plazo, En lugar de trabajar como las redes neuronales recurrentes en las cuales todos los nodos se interconectan también hay conexiones hacia los predecesores, estas celdas toman los vectores de entrada y de forma simultánea les dan tratamiento diferente en función de valores correspondiente a la historia cercana, valores correspondientes a la historia lejana y por supuesto los valores actuales.

Las celdas pueden ser vistas como una unidad que toma como entrada el estado previo y la entrada actual. Internamente estas celdas deciden qué información mantienen en la memoria u olvidan. Después combinan el estado previo, la entrada actual y la información en memoria actual. Así, este tipo de unidades son muy eficientes a la hora de hallar correlaciones entre eventos muy lejanos en el tiempo.

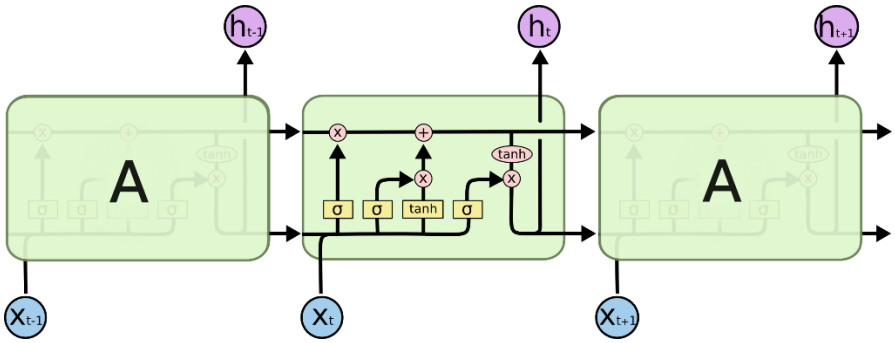

Gráfico 18 Representación de celda LSTM.

Fuente: https://programmerclick.com/article/3031293953/

Tomando como base la figura, vemos que la celda LSTM tiene una estructura de tipo cadena, pero el módulo de repetición tiene una estructura diferente. En lugar de tener una sola capa de red neuronal, hay cuatro que interactúan de una manera particular.

La clave de las redes LSTM es el estado de la célula, la línea horizontal que recorre la parte superior del diagrama. El estado de la célula es algo así como una cinta transportadora. Corre hacia abajo por toda la cadena, con solo algunas interacciones lineales menores. Es muy fácil que la información fluya sin cambios. El LSTM tiene la capacidad de eliminar o agregar información al estado de la célula, cuidadosamente regulado por estructuras llamadas compuertas.

Las puertas son una forma de permitir que la información fluya. Se componen de una capa de red neuronal sigmoidea y una operación de multiplicación puntual. La capa sigmoide produce números entre cero y uno, que describen la cantidad de cada componente que debe dejarse pasar. Un valor de cero significa “no dejar pasar nada”, mientras que un valor de uno significa “dejar pasar todo”. Un LSTM tiene tres de estas compuertas, para proteger y controlar el estado de la celda.

6.1.4.8. Celda GRU

La Gated Recurrent Unit (GRU) celda fue propuesta en 2014 (Chung, Gulcehre, Cho, & Bengio, 2014) introduciendo una red codificadora/descodificadora.

Esta celda es una versión simplificada de la celda LSTM, en ocasiones actúa mejor que la propia LSTM, que se concreta en:

- Los dos vectores de estado (corto plazo y largo plazo) se juntan en uno solo, ht.
- Una única puerta que controla tanto la forget gate, como la input gate, si el valor es 1, sería si la puerta de entrada estuviera abierta y la de borrado cerrada; si es 0 pasa lo contrario.
- No existe puerta de salida: todo el vector estado es la salida de cada paso.

Los cálculos son menores por lo que este algoritmo converge más rápido que las otras redes.

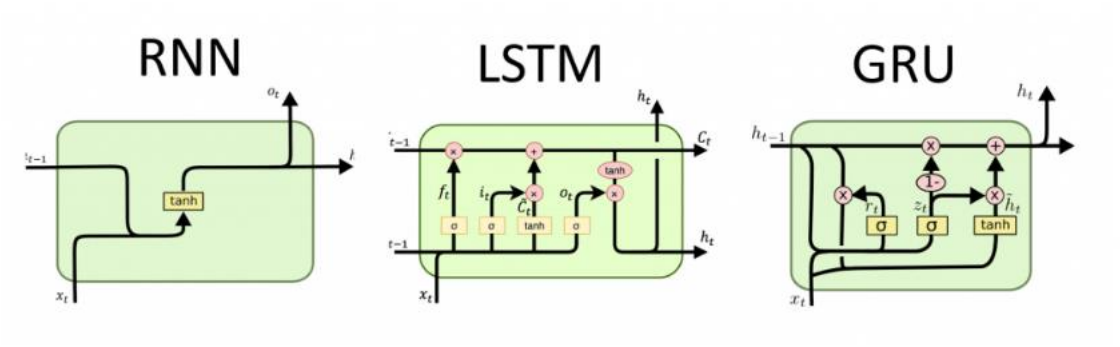

Gráfico 19 Representación de celda GRU.

Fuente: https://clay-atlas.com/us/blog/2021/07/27/gru-en-introduction-note/

6.1.5. Síntesis Redes Neuronales.

A modo de síntesis para cerrar el marco teórico referido a redes neuronales, nos parece importante recalcar que el machine learning es una disciplina de la informática que aborda la resolución de problemas desde una óptica distinta al abordaje desde la programación convencional, en la cual es necesario conocer en totalidad el problema y su resolución antes de buscar desarrollar una versión automatizada.

En los casos en los que no se conoce un algoritmo lógico para resolver una situación en particular, la aplicación de machine learning surge como una opción sumamente interesante.

Precisamente, en el caso concreto de este trabajo, no se conoce un algoritmo que pueda ser usado para predecir la evolución de los precios de una acción a partir de los precios anteriores, pero si es posible aplicar machine learning para intentar abordar esa problemática.

Dado que el proceso de aprendizaje supervisado es un método netamente empírico que dependerá de las colecciones de datos disponibles, como estas se fraccionan y de como se configuran parámetros esenciales del proceso, será importante iterar en la búsqueda de calibra los resultados.

En estas iteraciones será importante calibrar no solo las características y fracciones de los datos de entrada con los conjuntos de datos de salida sino también establecer valores para las funciones de activación, el tamaño de los saltos en las búsquedas y la cantidad de iteraciones en los procesos de aprendizaje.

6.2. Lenguajes y productos utilizados.

Para desarrollar el presente trabajo se toma como premisa la utilización de un lenguaje de programación y un paquete de productos de software de soporte que cumplan con las siguientes condiciones:

1) los paquetes de software a ser utilizados deben tener al menos una versión de acceso libre y gratuito, los mismos, deben poseer también un amplio desarrollo de documentación y ejemplos de libre acceso disponibles en internet junto a una adecuada comunidad de desarrollo.
2) el lenguaje de programación a utilizar debe ser también de acceso libre, debe gozar de un amplio grado de popularidad y ser ampliamente utilizado para desarrollar en conjunto con las librerías que se adopten, teniendo el poder suficiente para implementar las soluciones requeridas en el trabajo.

El lenguaje de programación seleccionado es Python dado que se ha podido verificar que goza de una amplia popularidad y que la misma sigue creciendo, haciendo muy sencillo encontrar ejemplos en internet sobre su utilización aplicada a redes neuronales.

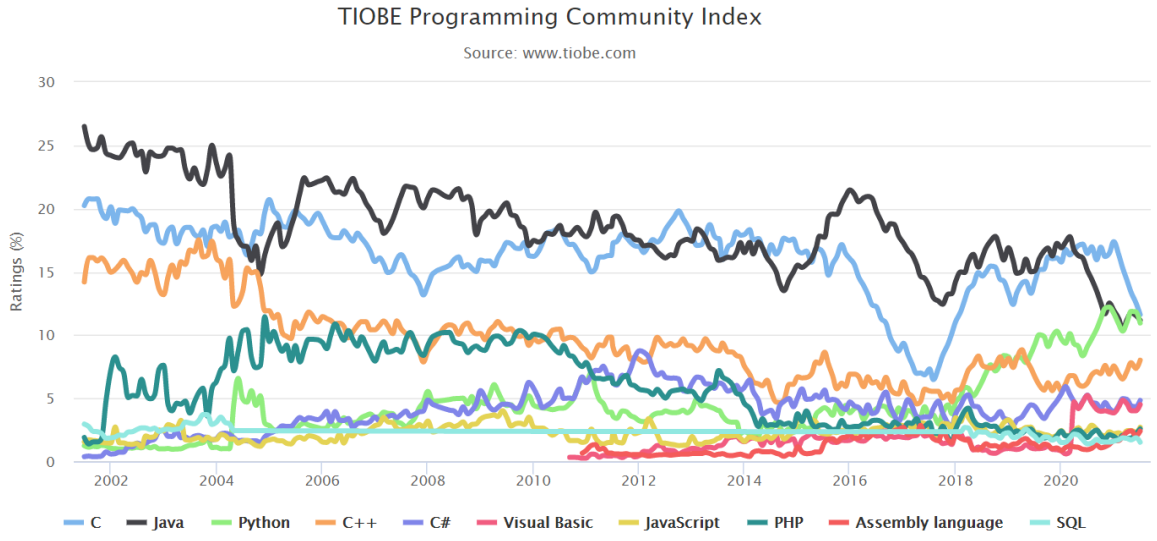

Gráfico 20 Curvas de adopción de lenguajes de programación.

Fuente: https://www.tiobe.com/tiobe-index/

Tomando como referencia el índice TIOBE, podemos notar que actualmente Python ocupa el tercer lugar en preferencia para lenguajes de programación habiendo crecido mucho en los últimos 3 años, paralelamente los otros dos lenguajes que pueden rivalizar en popularidad son menos utilizados en redes neuronales y por estas razones es la opción seleccionada.

Adicionalmente, es una premisa del trabajo utilizar software libre tanto para el lenguaje de programación como para todas las librerías y orígenes de datos a explotar.

Las principales opciones disponibles de software para implementar redes neuronales utilizando Python son Pytorch y Tensorflow/Keras.

Para la implementación de las redes neuronales en sí, hemos seleccionados Tensorflow/Keras.

Keras es un interfaz de programación de aplicaciones de redes neuronales de alto nivel escrita en Python. Esta solución proporciona una manera sencilla y rápida de definir y entrenar muchos tipos de modelos de aprendizaje profundo. Fue desarrollado con enfocado en permitir la experimentación rápida.

Con Keras nos podemos centrar en el diseño de las redes y su entrenamiento dejando un poco de lado los tecnicismos que hay por detrás. Las principales ventajas que proporciona esta librería son su facilidad de uso, su modularidad, su capacidad de ampliación y que trabaja con Python.

La estructura de Keras es un modelo, una forma de organizar capas. En este trabajo se utilizará un modelo combinado de varios modelos Sequential que consisten en una pila lineal de capas, en el que de forma sencilla se van añadiendo capas una detrás de otra.

El modelo resultante tendrá una estructura arborescente invertida similar a la siguiente figura:

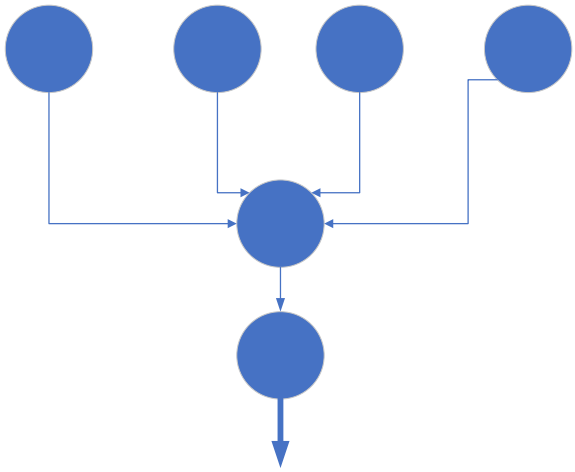

Gráfico 21 Representación esquemática del modelo de entradas múltiples.

Fuente: Elaboración Propia

Como alternativa a Keras existe la opción de Pytorch, que es también una solución enfocada en simplificar la experiencia y evitarle al programador entrar en los detalles de la resolución de la red, las ventajas que se le encuentra a Keras por sobre Pytorch son las siguiente:

- Una gran cantidad de módulos y un ecosistema más grande que Pytorch
- Una mayor cantidad de modelos pre-entrenados
- Una mayor cantidad de datasets para practicar
- Mayor facilidad de implementación y uso que Pytorch
- Más programadores están familiarizados con Tensorflow que con Pytorch.
- Documentación más extensa y con más ejemplos

De lo visto anteriormente respecto de machine learning, es relevante aclarar que el método que aplicaremos entra en la definición de aprendizaje supervisado, dado que la estrategia consistirá en tomar un conjunto de datos subdividirlo e ir aplicando

sucesivamente un entrenamiento asociando a cada grupo de precios utilizados, el precio de la jornada inmediatamente posterior a modo de entrenamiento.

6.3. Macroeconomía, definición y vinculación con los mercados bursátiles

La diciplina de la macroeconomía fundada por John Maynard Keynes dio sus primeros pasos en la década de 1930, tratando de comprender los mecanismos económicos que generaron la gran depresión. Pasada la segunda Guerra Mundial, y bajo la influencia de las ideas keynesianas, el congreso de los estados unidos termina declarando que los resultados macroeconómicos son responsabilidad federal (Samuelson & Nordhaus, 2003).

Los objetivos de la macroeconomía están asociados entonces a elevar el nivel de producción y crecimiento, mantener un nivel creciente de generación de empleo y minimizar el desempleo, manteniendo la estabilidad de los precios y el costo de vida.

Las economías muestran patrones de expansión y contracción que son conocidos como ciclos económicos. La macroeconomía analiza las causas y soluciones de estos ciclos. En ciclos recesivos se suele utilizar la política monetaria para favorecer la reactivación.

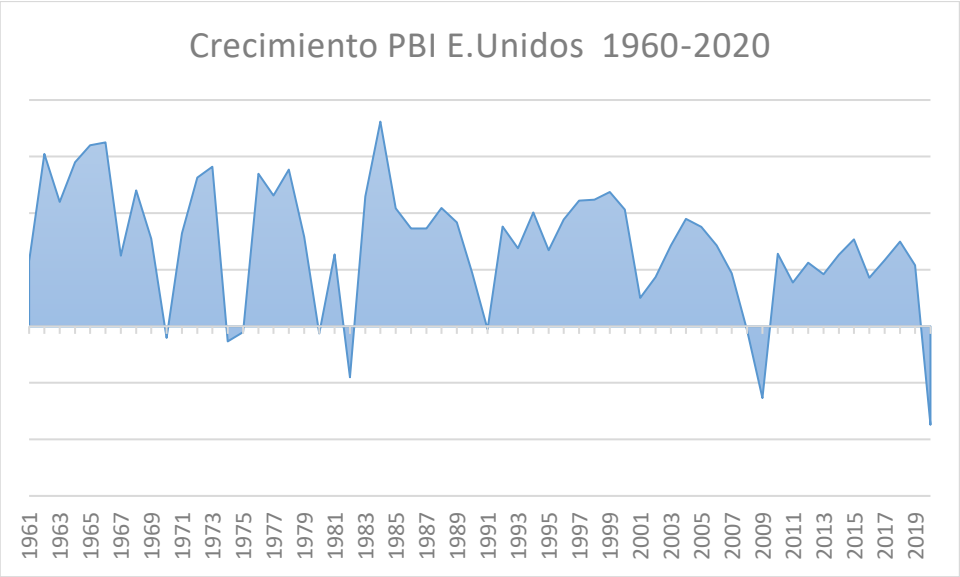

Gráfico 22 Evolución del PBI de EEUU.

Fuente: Banco Mundial

En ocasiones los países experimentan períodos de elevado desempleo, estos pueden llegar a extenderse en el tiempo, algo así experimentó Estados unidos durante la gran depresión que arrancó en 1929.

La macroeconomía examina las causas de ese comportamiento y además de intentar diagnosticarlo puede proponer estrategias para modificar estas condiciones. Estas medidas

pueden ser tales como la adopción de medidas expansivas de demanda o modificaciones del mercado de trabajo para eliminar incentivos para no trabajar o aumentando la flexibilidad salarial.

Una elevada tasa de inflación produce un efecto corrosivo en las economías de mercado. Estas utilizan los precios para medir los valores económicos y para gestionar las empresas. Una alta tasa de inflación genera ineficiencia en el mercado.

Una complicación que plantea el análisis de las 3 cuestiones fundamentales de la macroeconomía es la existencia de inevitables disyuntivas entre estos objetivos.

El aumento de la tasa de crecimiento de la producción a largo plazo puede exigir un aumento de la inversión, para aumentar la inversión es necesario reducir el consumo actual.

El más angustioso de los dilemas macroeconómicos es la disyuntiva entre desempleo e inflación. Si la producción aumenta demasiado, el desempleo disminuye, se elevan precios y salarios. Se hace necesario un freno en la economía a fin de evitar la inflación. No hay una formula sencilla para resolver estos dilemas, y los macroeconomistas discrepan en los enfoques a adoptarse ante la inflación, el desempleo o un estancamiento del crecimiento.

Para alcanzar estos objetivos se cuenta con instrumentos como la política monetaria, la política fiscal y políticas ortodoxas de tipo monetaristas o heterodoxas (estructuralistas o políticas de renta).

Objetivos	Instrumentos
• Elevar el nivel de producción y crecimiento • Elevar el nivel de empleo • Mantener estabilidad de los precios	• Política Monetaria • Politica Fiscal • Políticas de estabilización

La política monetaria, es la utilizada por los gobiernos al gestionar el dinero, el crédito y el sistema bancario del país.

El dinero es el medio de cambio o método de pago. Al realizar operaciones, el banco central puede regular la cantidad de dinero que dispone la economía.

Mediante la alteración de la oferta monetaria, se puede influir en muchas variables financieras y económicas como las tasas de interés, **los precios de las acciones**, los precios de la vivienda y los tipos de cambio.

Restringiendo la oferta monetaria, suben las tasas de interés y disminuye la inversión, lo que provoca una reducción del PBI y de la inflación. Si en cambio se enfrenta a una recesión económica, el banco central puede aumentar la oferta monetaria y bajar las tasas de interés para estimular la actividad económica.

La política fiscal, se refiere a la utilización de los impuestos y del gasto público.

El gasto público indica que parte del PBI se consume colectivamente. Afecta en el nivel global de gastos y por lo tanto en el PBI. El gasto realizado por el gobierno incide en la relación existente entre el gasto colectivo y el consumo privado.

Los impuestos contraen los ingresos, reducen el consumo privado y afectan al ahorro privado. Además, inciden en la inversión y en el producto potencial.

La política fiscal se utiliza principalmente para afectar al crecimiento económico de largo plazo por su impacto en el ahorro e inversión nacionales.

La otra parte de la política fiscal son los Impuestos, afecta a la economía al reducir la renta disponible, afectando por lo tanto en la cantidad de bienes y servicios en que se gasta, así como la cantidad que se ahorra.

El consumo y ahorro influyen en la producción e inversión a corto y largo plazo. A su vez, afectan los precios de los bienes y factores de la producción y por lo tanto a los incentivos y la conducta.

Demanda y Oferta Agregada.

Para tratar de explicar las tendencias en producción y precios los economistas han desarrollado el análisis de la demanda y oferta agregadas.

Oferta agregada: corresponde a la cantidad total de bienes y servicios que las empresas de un país están dispuestas a producir y vender en determinado período de tiempo.

La oferta agregada depende del nivel de precios, la capacidad productiva (producción potencial) y el nivel de costos.

La producción potencial depende de la existencia de factores productivos y la eficiencia en la gestión y combinación de estos.

Demanda agregada: corresponde a la cantidad total que están dispuestos a gastar los diferentes sectores de la economía en un determinado período de tiempo.

La suma del gasto de los consumidores, empresas y Estado.

La demanda agregada depende del nivel de precios, la política monetaria y fiscal y otros factores.

La producción nacional y el nivel de precios se asientan en el punto en el que los demandantes están dispuestos a comprar lo que las empresas están dispuestas a vender.

El nivel de producción y de precios resultante, determinan el empleo, desempleo y comercio exterior.

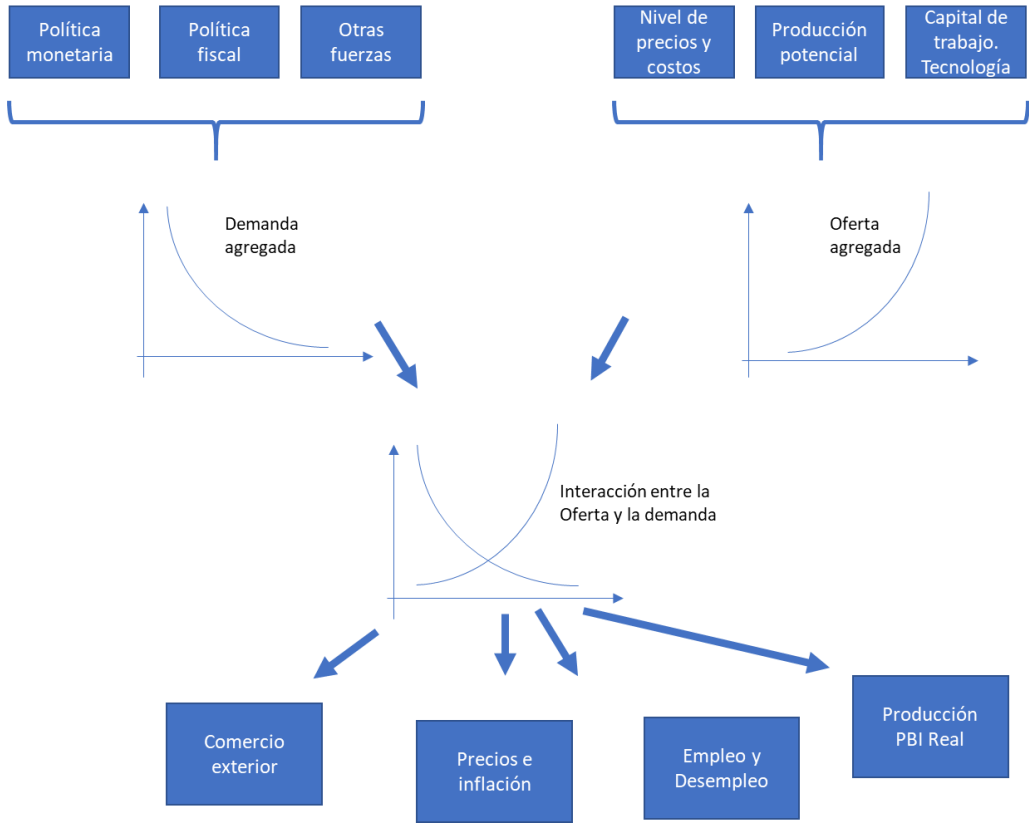

Gráfico 23 Interacciones de las Macroeconomía.

Fuente: (Samuelson & Nordhaus, 2003)

Equilibrio macroeconómico es una combinación del precio y cantidad globales que satisface a los consumidores y a los productores con sus compras, ventas y precios globales.

Si el nivel de precios fuera mayor al de dicho equilibrio, las empresas querrían vender más de lo que los consumidores querrían comprar y como la oferta agregada excedería a la demanda agregada los precios tenderían a bajar, por el contrario, cuando las empresas no producen al mismo nivel que la demanda agregada se genera una situación en la que los precios tienden a subir.

En el **equilibrio macroeconómico** no habría ni excedente ni escasez, tampoco presión para modificar el nivel general de precios.

Producto Bruto Interno: Es el indicador más amplio de la producción total de bienes y servicios de un país. Es la suma de los valores de Consumo, Inversión Bruta, Gasto Público y Exportaciones Netas, producidas en un país durante un determinado año. El PBI se utiliza para muchos fines, el más importante de ellos es medir el comportamiento global de una economía.

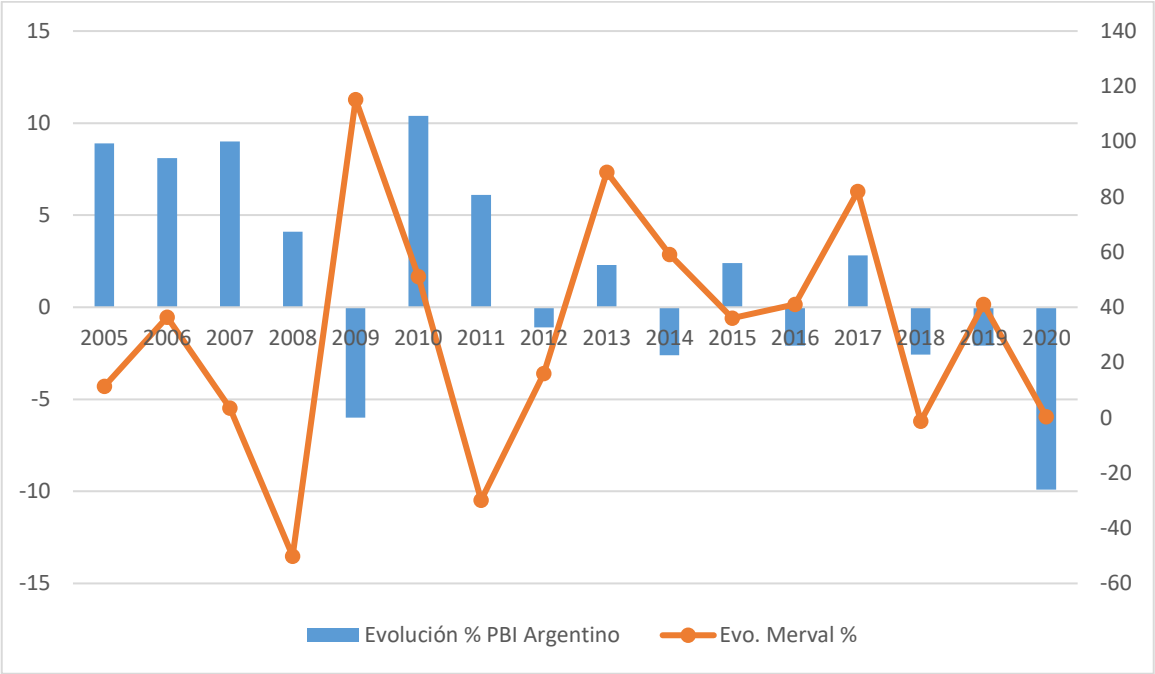

Gráfico 24 Evolución del PBI y del índice Merval.

Fuente: Indec para evolución de PBI y BCRA para evolución del Merval.

<u>Ingreso Públicos:</u> Los ingresos públicos son todos los recursos que posee el Estado y que éste afecta a la consecución de sus fines.

Desde el punto de vista económico se dividen en:

- Ingresos corrientes: aquellos que logra el Estado sin contraer endeudamiento ni disminuir sus activos (por ej, ingresos tributarios)
- Ingresos no corrientes o de capital: aquellos que obtiene endeudándose con el sector público o privado, o cambiando el valor de sus activos.

El estado en tanto administrador de las policitas que influyen en la macroeconomía busca alcanzar los siguientes objetivos:

1.Mejorar la eficiencia Económica

Es un objetivo fundamental del Estado el contribuir a la asignación socialmente deseable de los recursos. Se trata del aspecto microeconómico de la política económica, que centra la atención en el qué y cómo de la vida económica.

Esto varía de acuerdo con las costumbres e ideas políticas: mientras que algunos ponen énfasis en un enfoque no intervencionista, otros se inclinan por una intensa regulación publica o, incluso, por la propiedad de las empresas.

En ocasiones, el Estado utiliza sus armas para corregir las fallas importantes del mercado, como, por ejemplo:

- **La quiebra de la competencia perfecta** (el Estado aplica por ejemplo políticas antimonopólicas)
- **Las externalidades y los bienes públicos.** El Estado puede hacer valer su influencia para controlar las externalidades perjudiciales o para financiar programas de ciencias y de salud pública. El Estado puede gravar actividades que imponen costos públicos o externos o subvencionar las que son socialmente beneficiosas.
- **La información imperfecta**. Los mercados que no están regulados pueden suministrar demasiado poca información a los consumidores para tomar decisiones bien documentadas. Eso llevo a aprobar normas sobre alimentos, productos farmacéuticos que obligan a suministrar al Estado abundantes datos sobre la seguridad y eficacia.

2.Mejorar la distribución de la renta

Incluso cuando la mano invisible funciona y es maravillosamente eficiente, puede generar una distribución muy desigual de la renta.

La mayoría de los países industrializados y de desarrollo intermedio, destinan actualmente una importante proporción de sus ingresos al mantenimiento de unos niveles mínimos de salud, nutrición y renta.

La renta se redistribuye normalmente por medio de la política de impuestos y de gasto, aunque la regulación también desempeña a veces un papel importante.

3.Estabilizar la economía por medio de la política macroeconómica

El Estado es responsable hoy en día de evitar las depresiones cíclicas utilizando de manera correcta la política monetaria y fiscal, regulando también el sistema financiero.

Es estado también trata de allanar las oscilaciones del ciclo económico. Los gobiernos han tratado de encontrar medidas económicas que aumenten el crecimiento económico a largo plazo. Así, en la teoría económica del desarrollo, se introduce al Estado como promotor de la expansión económica y del cambio estructural global.

Se recomiendan en este sentido políticas públicas que tiendan a la industrialización y al equilibrio social y regional, y un buen funcionamiento del capitalismo en los países periféricos.

4.Gestionar la política económica internacional

El comercio y las finanzas internacionales han cobrado mucha importancia. Actualmente el Estado desempeña un papel fundamental en la representación de los intereses de los países en la esfera internacional y en la negociación de acuerdos beneficiosos. Las cuestiones internacionales se pueden agrupar en tres grandes áreas:

- **Reducir las barreras comerciales**. Al armonizar la legislación y reducir las barreras comerciales, se fomenta la especialización y división internacional del trabajo. En este sentido se negocian tratados de libre comercio como el MERCOSUR, por ejemplo.
- **Coordinación de la política macroeconómica**. Los países han observado que el aumento de su interdependencia económica significa que deben coordinar su política macroeconómica para luchar contra la inflación y el desempleo. Se fijan sistemas de tipos de cambio para que el comercio internacional sea eficiente. Se coordina la política fiscal, monetaria y de tipo de cambio o incluso adoptan una moneda única, como fue el caso del Euro.
- **Protección del medio ambiente global.** La faceta más reciente de la política económica internacional es el trabajo realizado con otros países para proteger el medio ambiente en los casos en los que varios países producen fugas contaminantes o son afectados por ellas.

El Gasto Público.

El gasto público constituye una aplicación de recursos del Estado para la consecución de sus fines.

Son transacciones financieras que realizan instituciones públicas para adquirir bienes y servicios que requieren para la producción pública o para transferir los recursos recaudados a diferentes destinatarios.

Se clasifica en:

- **Gastos corrientes.** Corresponden al normal funcionamiento del Estado.
- **Gastos de capital o inversión**. Su objetivo es aumentar la capacidad productiva del sector público.

- **Gastos de transferencia.** Erogaciones que realiza el Estado que no generan obligación o contraprestación por parte de los beneficiarios.

Otra forma de clasificar el gasto público es la funcional, que discrimina las categorías según su destino o su funcionalidad.

Relación entre la macroeconomía y los mercados de capitales.

El crack bursátil que sucedió en 1929 elevó la aparición de estudios tendientes a analizar en profundidad la relación entre la economía y las finanzas.

La crisis económico-financiera surgida a nivel mundial en el año 2008, ha intensificado el análisis en todos los ámbitos, desde el académico al periodístico, de la relación entre la macroeconomía y las finanzas. Se discuten causas, teorías de predicción o formas de prevención entre otros, así como el papel que juega y la influencia que ejercen las medidas de política monetaria desarrolladas por los principales bancos centrales para intentar paliar los efectos de dicha crisis, y cómo pueden afectar al crecimiento económico y a la evolución de los mercados financieros.

Los mecanismos financieros canalizan el ahorro y la inversión. Generan rendimientos del ahorro con los que es posible el desarrollo de nuevas y mejores tecnologías de producción para la economía. Así fomentan y favorecen la especialización, la innovación tecnológica y el crecimiento económico sostenido a largo plazo.

El sistema financiero de los países puede ser dividido en dos partes distintas dentro de su configuración: el sistema bancario y el mercado de capitales.

Investigaciones como la de Levine y Zervos (1996) demuestran que el desarrollo de los mercados de capitales contribuye al crecimiento económico a largo plazo en los países.

Para ello recopilan datos de cuarenta y un países, abarcando un periodo de 1976 a 1993, sobre los que realizan un proceso de regresiones lineales sobre series temporales. Ensus resultados, estos autores concluyen que aquellos países con mercados de capitales desarrollados, medidos en función de una serie de índices que miden su tamaño, liquidez e integración, contribuyen definitivamente al crecimiento económico a largo plazo.

De la misma forma, Levine y Zervos (1996) demuestra empíricamente la mencionada relación entre crecimiento económico y desarrollo de los mercados de capitales y del sistema bancario de los países, utilizando en este caso la técnica de mínimos cuadrados ordinarios. Estos autores encuentran que un grupo de indicadores de la liquidez del

mercado bursátil y del desarrollo bancario son fuertes predictores de crecimiento económico. (Levine & Zervos, 1996)

Hoy en día, especialmente tras la crisis financiera recientemente vivida que empezó a propagarse en 2008, son muy consideradas las teorías de Minsky, que planteo en 1974 que una característica fundamental de nuestra economía es que el sistema financiero oscila entre la robustez y la fragilidad, y esa oscilación es parte integrante del proceso que generan los ciclos económicos. (Minsky H. P., 1974)

Según Minsky, es empíricamente fácil constatar que las economías capitalistas experimentan de vez en cuando procesos de inflación o de deflación por sobreendeudamiento que parecen potencialmente peligrosos. Dichos episodios históricos suponen de esta forma una evidencia contraria a los preceptos clásicos de Smith o Walras, que conciben la economía como un sistema estable en constante búsqueda del equilibrio (Minsky H. , 1992). “Las depresiones más severas de la historia se presentan después de un periodo de buen desempeño económico, donde sólo ciclos menores perturban la expansión general de la economía”.

Minsky desarrolló lo que denominó la “hipótesis de la inestabilidad financiera”, que parte del núcleo de la Teoría General de Keynes, del quien fue su discípulo. En dicha hipótesis se establece que una economía capitalista podría llegar a experimentar ciclos económicos de diferentes gravedades por sí misma, independientemente de las posibles perturbaciones externas que la afecten, ya que estos ciclos se generan simplemente por la propia dinámica interna de las economías capitalistas y del conjunto de intervenciones y regulaciones establecidas para que la economía opere dentro de unos límites razonables.

Dentro de las problemáticas financieras presentes en las crisis, otros estudios van a introducir aquéllas principalmente ocasionadas por las imperfecciones del canal del crédito o por la política monetaria. Se pueden consultar el respecto algunas publicaciones (Gertler, 1988) (Jaffee & Stiglitz, 1990) (Bernanke, 2010).

Es posible extraer como conclusión de lo expuesto la existencia de una relación entre la macroeconomía y el sistema financiero.

6.4. Variables de la macroeconomía seleccionadas para la investigación.

Para definir que variables representativas de la macroeconomía se evaluarán se considera no solo la relevancia que esta variable puede llegar a tener sino también la posibilidad de obtener series históricas de la misma.

Variables seleccionadas:

- Tipo de Cambio
- Contado con Liquidación (debido a la existencia de múltiples tipos de cambio, se analiza el Contado con liquidación que puede llegar a estar menos distorsionado que el tipo de cambio oficial).
- Base Monetaria
- Tasa
- C.E.R Coeficiente de estabilización de referencia (en representación de la inflación)
- Depósitos totales en el sistema bancario.
- Riesgo País.

7. El Proyecto

Una vez concluidas las fases de búsqueda de datos y disponiendo de todas las series de precios con las que se realizará el trabajo se prevé un enfoque incremental basado en iteraciones sucesivas.

Inicialmente se partirá de una red neuronal sencilla tomando como entrada un conjunto de precios, pero luego se avanzará en complejizar esta red partiendo de múltiples entradas entre las que están la serie de precios y se les incorporara diferentes series cómo ser:

- Indicador de medias móviles (esta es una serie armada a partir de la serie de precios y suele ser útil para introducir en la red un factor de tendencia suavizada).
- Tipo de cambio del dólar
- Valor del índice merval
- Valor del índice Standard and poor 500
- Cotización de la soja
- Valor del barril Brent de petróleo

En todos los casos la serie de precios utilizada como entrada será ingestada en una red con celdas de tipo LSTM debido a que son estas el tipo de celda recomendadas para tratar con series de tiempo. no será ese el caso del resto de las series de valores que se utilizarán, las cuales serán injertadas en células de tipo DENSE.

7.1. Equipamiento utilizado.

Para los desarrollos en Python y para los entrenamientos de prueba o aquellos en los que se utilizaron datos pequeños el equipamiento que se dispuso es el siguiente:

Notebook Dell Latitude 7410

Procesador: Intel Core i7 10610U 10Th Generation 2,3Ghz

Memora: 16 GigaBytes

Para todos los desarrollos y entrenamientos que requirieron el mayor Poder computacional disponible se utilizó el siguiente equipamiento:

PC de Escritorio

Procesador Intel Core I7 11700 11Th Generation 3,6Ghz

Memoria: 16 GigaBytes

Se utilizó Python versión 3.8.5 a través de toda la suite de Anaconda versión 3

Para las redes neuronales se utilizó Tensorflow versión 2.3.0

Los sets de datos fueron procesados con Pandas versión 1.2.4

Los Arrays con numpy versión 1.19.0 (en el caso de numpy ha sido necesario hacer un downgrade porque la versión 1.20 que viene con el pack de Anaconda es incompatible con tensorflow).

7.2. Orígenes de los datos de trabajo.

Los orígenes de datos seleccionado para las series de precios de las acciones que van a ser estudiadas han sido descargados de:

https://es-us.finanzas.yahoo.com/

Las cotizaciones históricas para el tipo de cambio de conversión dólar estadounidense contra el peso argentino han sido descargadas y recopiladas de la página web:

https://dolarhistorico.com/

Los valores históricos del índice merval han sido descargados de la página web:

https://www.puentenet.com/

Las cotizaciones del barril Brent de petróleo han sido descargadas de la página web:

https://es-us.finanzas.yahoo.com/

Las cotizaciones del valor por tonelada en la bolsa de cereales de Chicago para la soja han sido descargadas de la página web:

https://www.puentenet.com/

Los orígenes de datos considerados para las variables que representan o influyen en el comportamiento de la macroeconomía y que serán utilizadas para analizar la relación de

las mismas con la capacidad de predicción de las redes entrenadas han sido Descargadas de las páginas del Banco Central de la República Argentina y del Instituto nacional de estadística y censo.

http://www.bcra.gob.ar/Pdfs/PublicacionesEstadisticas/seriese.xls

7.3. Tratamiento de la entrada de la serie de precios para entrenar una red LSTM.

El mecanismo seleccionado para preparar la serie de precios de las acciones y efectuar los entrenamientos de las redes consiste en todos los casos en el armado de N-uplas con N cotizaciones y el subsiguiente valor, es decir

Por ejemplo: dada una serie de cotizaciones, si se decide armar un conjunto bloques de 5 cotizaciones para el entrenamiento, se fraccionará la serie en sendos bloques que contengan cinco cotizaciones consecutivas y el valor de la subsiguiente.

Es decir para predecir el valor de x_t en un caso ejemplo de 5 cotizaciones, se armará una n-upla de entrada que contendrá los valores (x_{t-5}, x_{t-4}, x_{t-3}, x_{t-2}, x_{t-1}) y (x_t) a modo de salida.

Ejemplo a partir de las cotizaciones de YPF para la segunda quincena del mes de Junio de 2019 tomando como tamaño de las tuplas 5 previas más 1, es decir (x_{t-5}, x_{t-4}, x_{t-3}, x_{t-2}, x_{t-1}) y (x_t).

Fecha	Precio	TUPLA(5+1)					
28/6/2019	780,5						
27/6/2019	788,1						
26/6/2019	778						
25/6/2019	771						
24/6/2019	771,1						
21/6/2019	784						
19/6/2019	762,4						
18/6/2019	770						
14/6/2019	752	771	771,1	784	762,4	770	752
13/6/2019	746	771,1	784	762,4	770	752	746
12/6/2019	750	784	762,4	770	752	746	750
11/6/2019	742	762,4	770	752	746	750	742
10/6/2019	723,5	770	752	746	750	742	723,5
7/6/2019	702,5	752	746	750	742	723,5	702,5
6/6/2019	686	746	750	742	723,5	702,5	686
5/6/2019	675,35	750	742	723,5	702,5	686	675,35
4/6/2019	679	742	723,5	702,5	686	675,35	679
3/6/2019	671	723,5	702,5	686	675,35	679	671

Tabla 1 Formación de las Tuplas de entrenamiento

7.4. Separación de los conjuntos de datos.

En todos los casos ante una serie de valores utilizados para entrenar la red se tomará como criterio la utilización de un porcentaje mayoritario de estos valores para el entrenamiento en sí y la utilización de los valores restantes para hacer una comprobación de las predicciones contra lo que efectivamente sucedió y de esa forma poder evaluar la capacidad de la red.

En todos los casos se tomará para la totalidad de las series un 80% de los valores con el fin de efectuar el entrenamiento y el 20% restante será utilizado como comprobación de resultados, es decir, simulando no disponer de esos datos se hará que la red efectúe una predicción de los mismos y luego se comparará la predicción con los valores reales reservados para hacer la comprobación. se entenderá como acierto aquellos casos en los que la red predijo un movimiento similar al que se produjo en el mercado, es decir, la red predice suba y la acción subió o la red predice baja y la acción bajo.

7.5. Primera prueba.

La primera red con la que se efectuaron pruebas consistió en un tren de capas simple LSTM tomando como ingreso exclusivamente el histórico de precios de la acción en forma de tuplas, los resultados obtenidos no fueron considerados lo suficientemente significativos como para utilizar esta red en la investigación definitiva. Este primer intento arrojó los siguientes resultados en porcentajes de aciertos.

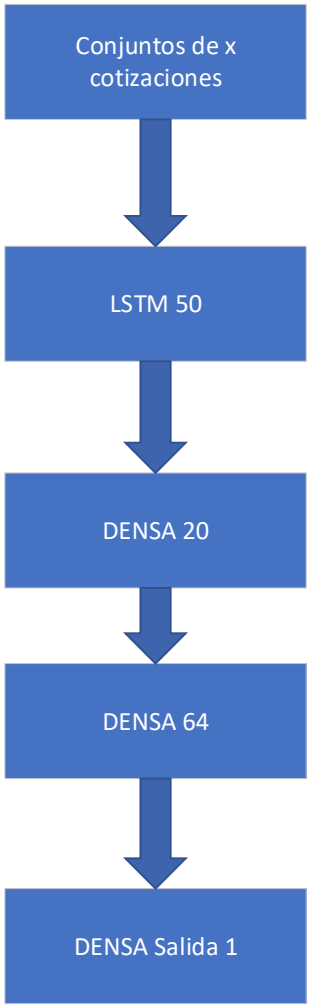

Gráfico 25 Esquema secuencial de primera red.

Fuente: Elaboración propia

Se probaron diferentes configuraciones de ventana para medir los resultados obteniendo la siguiente performance para cada caso:

Ventana	Aciertos
5	47,14%
10	46,89%
20	46,63%
30	45,41%
40	47,57%
50	46,83%

Tabla 2 Resultados alcanzados para diferentes ventanas

La acción seleccionada para esta primera prueba fue YPF.

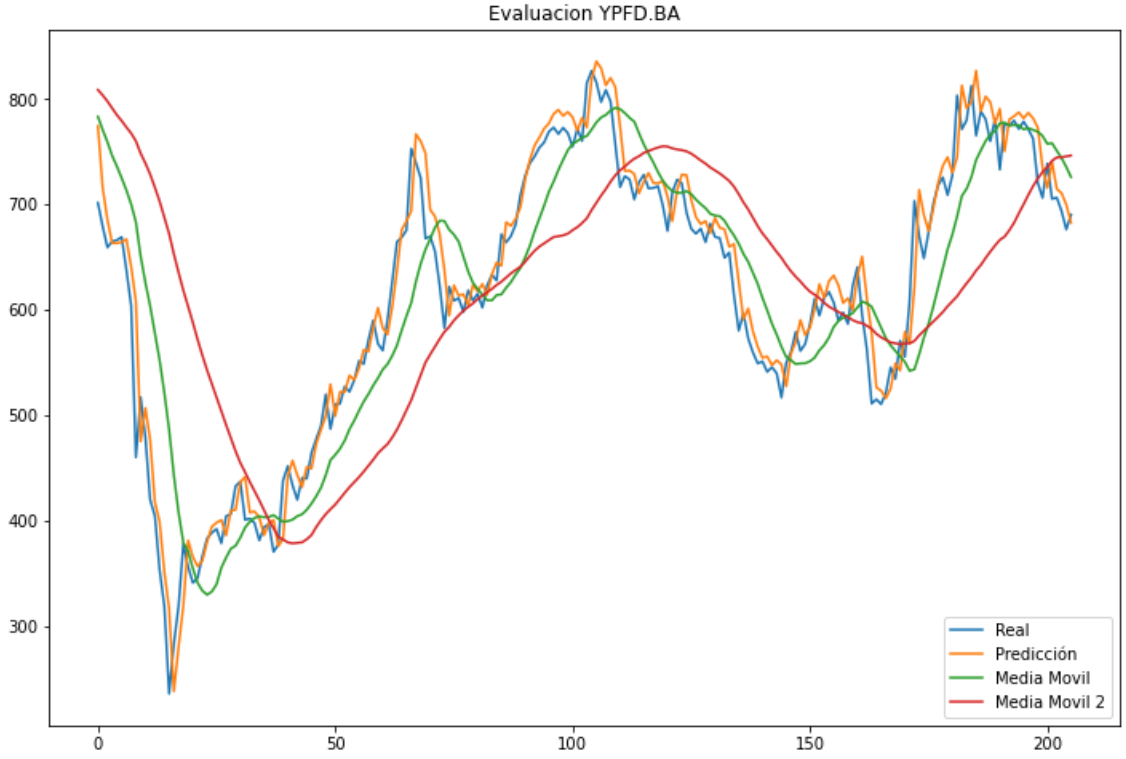

Gráfico 26 Curvas Reales, predicha y medias móviles.

Fuente: Elaboración propia

7.6. Iteraciones en búsqueda de mejoras.

Como mejora se procedió al armado de una red de múltiples entradas la cual fue probada con múltiples acciones y parámetros.

Las acciones seleccionadas para las pruebas son las siguientes:

Ticker	Acción	Rubro
EDN	Edenor S.A.	Energía
YPFD	YPF S.A.	Energía
GGAL	Grupo Financiero Galicia S.A.	Banca
CEPU	Central Puerto S.A.	Energía
CRES	Cresud S.A.	Agroindustria
ALUA	Aluar S.A.	Aluminio
PAMP	Pampa S.A.	Energía

Tabla 3 Lista de acciones evaluadas

```
( Failed to import pydot. You must "pip install pydot" and install graphviz
(https://graphviz.gitlab.io/download/), ', 'for `pydotprint` to work.')
Epoch 1/50
53/53 [==============================] - 11s 214ms/step - loss: 0.2000 -
val_loss: 0.0021
Epoch 2/50
53/53 [==============================] - 10s 189ms/step - loss: 0.0023 -
val_loss: 0.0028
Epoch 3/50
53/53 [==============================] - 9s 175ms/step - loss: 0.0015 -
val_loss: 0.0030
Epoch 4/50
53/53 [==============================] - 10s 186ms/step - loss: 0.0014 -
val_loss: 0.0028
Epoch 5/50
53/53 [==============================] - 12s 226ms/step - loss: 0.0013 -
val_loss: 0.0027
Epoch 6/50
53/53 [==============================] - 12s 232ms/step - loss: 0.0012 -
val_loss: 0.0029
Epoch 7/50
53/53 [==============================] - 9s 178ms/step - loss: 0.0013 -
val_loss: 0.0031
Epoch 8/50
53/53 [==============================] - 9s 178ms/step - loss: 0.0013 -
val_loss: 0.0033
```

Gráfico 27 Captura de consola de salida durante el entrenamiento.

Fuente: Consola de Spyder

El mecanismo seleccionado para preparar la serie de precios de las acciones y efectuar los entrenamientos de las redes consiste en todos los casos en el armado de N-uplas con N cotizaciones y el subsiguiente valor, es decir, por ejemplo:

Dada una serie de cotizaciones, si se decide armar un conjunto bloques de 5 cotizaciones para el entrenamiento, se fraccionará la serie en sendos bloques que contengan cinco cotizaciones consecutivas y el valor de la subsiguiente, es decir la sexta en ese orden.

Como segunda variante se configuró una red neuronal con 4 entradas qué consisten en:

- La serie de precios de la acción
- La media móvil para un periodo corto
- La media móvil para un periodo más largo
- El volumen diario operado.
-

El diagrama esquemático de la red utilizada es el siguiente:

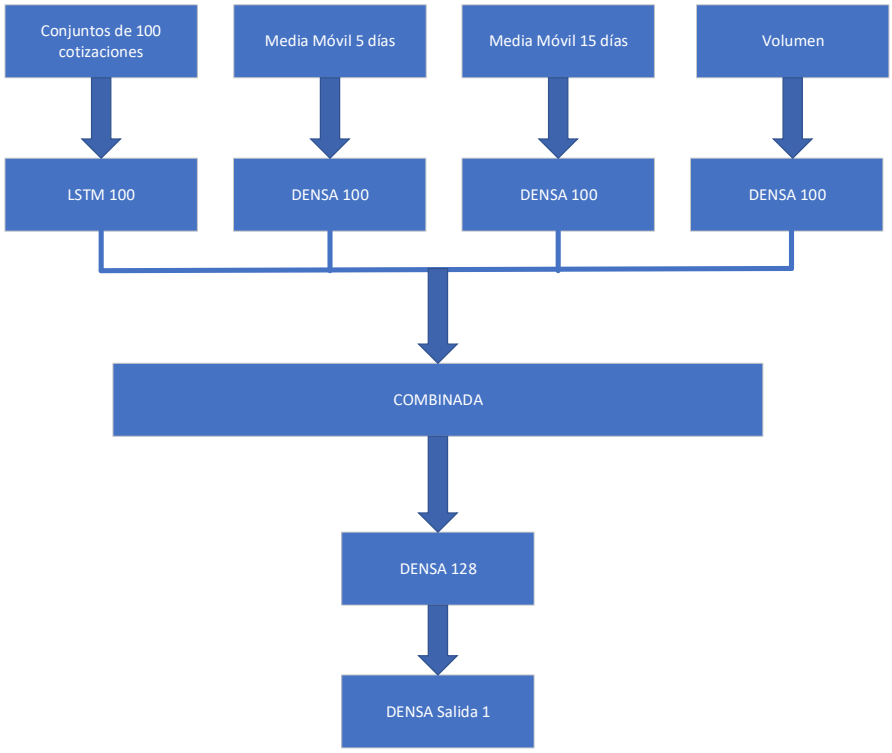

Gráfico 28 Esquema de red de múltiples entradas utilizada.

Fuente: Elaboración propia

Con esta red se efectuaron un conjunto preliminar de pruebas y el resultado arrojado en el mejor de los casos obtuvo un nivel promedio de aciertos de predicción del 55,141%.

Corridas	Ventana de Cotizaciones	Media Móvil 1	Media Móvil 2	Epochs	Aciertos/ Promedio	Desv/ Estándar
1	100	5	15	50	55,141%	4,069%
2	120	5	20	50	54,978%	2,304%
3	210	5	20	50	53,061%	3,035%
4	90	5	20	50	51,883%	3,090%

Tabla 4 Resultados obtenidos en diferentes corridas

Analizando más en detalle la corrida número 2 (hemos seleccionado esta porque si bien alcanzó un nivel promedio ligeramente menor ha sido el caso en el cual los niveles de acierto para las diferentes acciones han sido más similares entre sí), al graficar la evolución de la relación entre aciertos y errores a lo largo del tiempo podemos encontrar períodos en los cuales el nivel de aciertos se acelera y podemos hallar momentos en los cuales dicha aceleración parece coincidir para varias de las diferentes acciones evaluadas.

Continuando con la búsqueda de la configuración adecuada de la red neuronal para ejecutar la investigación referida a los momentos en los que la capacidad de predicción se maximiza en función del comportamiento de la macroeconomía se procedió a incorporar una quinta variable de entrada consistente en la serie de cotizaciones del índice Merval. La red entonces adoptó el siguiente formato esquemático:

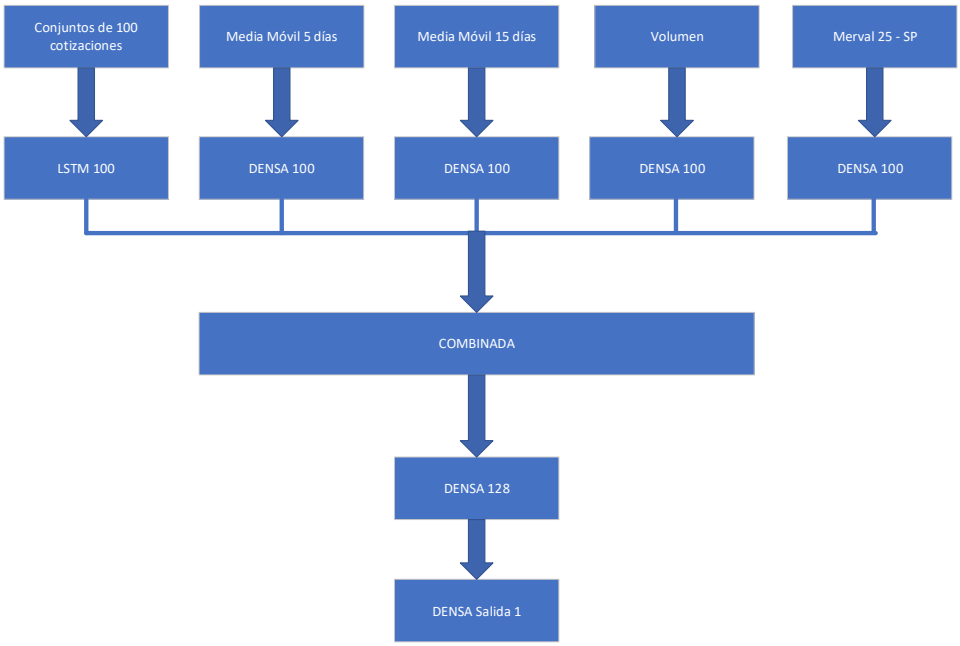

Gráfico 29 Esquema de red de 5 entradas.

Fuente: Elaboración propia

Se efectuaron 112 pruebas siendo las mejores 15 las siguientes:

Ventana	Media 1	Media 2	Epochs	Promedio de Positivos	Desv. Estandar	EDN	YPFD	GGAL	CEPU	CRES	ALUA	PAMP
5	5	20	40	**54,46**	2,49	53,39	53,39	57,01	52,70	58,82	53,85	52,04
220	5	20	10	54,07	2,51	52,50	54,50	58,50	54,50	55,50	51,50	51,50
150	5	20	10	54,04	3,15	53,62	57,49	57,97	53,14	55,56	50,24	50,24
10	5	20	50	53,98	**2,18**	55,20	52,04	54,30	52,04	57,47	55,20	51,58
20	5	20	10	53,96	3,69	53,64	56,36	57,73	51,36	58,64	49,09	50,91
20	5	20	30	53,90	2,90	56,82	51,82	55,45	51,36	58,18	52,73	50,91
120	5	20	10	53,88	4,48	54,76	57,62	59,52	52,86	56,19	48,57	47,62
40	5	20	30	53,87	3,70	55,05	52,29	57,34	52,75	59,63	49,08	50,92
20	5	20	50	53,77	2,80	54,55	51,36	54,09	51,82	59,55	52,27	52,73
220	5	20	40	53,71	2,46	53,00	52,50	57,50	52,50	57,00	52,00	51,50
150	5	20	20	53,69	3,50	53,14	54,11	57,49	53,62	58,45	50,24	48,79
150	5	20	40	53,69	2,62	51,21	51,21	57,00	52,17	57,49	54,11	52,66
10	5	20	40	53,65	2,81	56,56	51,58	54,30	49,77	57,47	54,30	51,58
20	5	20	20	53,64	3,95	53,64	55,45	56,82	51,36	59,55	48,18	50,45
70	5	20	70	53,62	3,02	50,70	54,88	51,63	53,95	57,21	57,21	49,77
50	5	20	20	53,59	3,44	56,22	52,07	58,06	51,15	57,14	50,69	49,77

Tabla 5 Resultados obtenidos en diferentes corridas

7.7. Mejora a la configuración de la red

Como no se conoce un mecanismo para definir la configuración ideal de la red a utilizar, se procede a ejecutar sucesivas iteraciones con el objeto de introducir pequeñas modificaciones a la definición de la red y testear los resultados obtenidos, En estas iteraciones los criterios de cambio abarcan desde la configuración de las capas de la red, ejemplo cantidad de capas, tamaño de las mismas, también los algoritmos de optimización utilizados y la parametrización de los mismos.

La gran mayoría de las pruebas fueron hechas utilizando el algoritmo de optimización Adam dado a que éste es el recomendado para la predicción de series de tiempo, En el caso de la parametrización de este algoritmo se trabajó variando el parámetro “Learning Rate”, Es relevante aclarar que todos los ejemplos previos a este párrafo se hicieron utilizando un valor para el learning rate de 0,0005.

Para definir la mejor opción del learning rate, se procedió a iterar con diferentes valores.

Para seleccionar el valor de learning rate se estableció un ciclo de corridas con ventanas De 10 a 100 cotizaciones y 50 epochs, el learning rate evaluado fue desde 0,0001 a 0,0004. siempre teniendo en cuenta que todas las pruebas anteriores fueron con un learning rate de 0,0005.

De los resultados obtenidos entendemos que los mejores valores para el learning rate son 0,0004 y 0,0005.

Ventana	Media 1	Media 2	Epochs	Lrs	Promedio Pos	EDN	YPFD	GGAL	CEPU	CRES	ALUA	PAMP
100	5	20	50	0,0004	54,48	55,71	51,90	51,90	54,97	54,98	59,52	52,38
30	5	20	50	0,0003	54,09	54,84	54,84	51,15	54,04	59,17	54,38	50,23
50	5	20	50	0,0004	53,64	53,49	51,63	53,49	57,14	57,87	50,70	51,16
70	5	20	50	0,0003	53,46	51,64	54,46	52,11	56,19	57,01	55,87	46,95
10	5	20	50	0,0004	53,19	55,25	51,60	51,14	52,00	52,73	56,16	53,42
30	5	20	50	0,0002	53,02	49,77	53,00	52,53	52,53	60,09	52,53	50,69
50	5	20	50	0,0001	52,92	52,09	58,14	56,74	52,55	55,56	48,84	46,51
30	5	20	50	0,0001	52,83	50,69	56,68	57,60	53,03	55,05	48,39	48,39
50	5	20	50	0,0002	52,78	51,63	53,02	54,88	52,04	58,80	50,23	48,84
100	5	20	50	0,0001	52,55	50,95	52,86	56,19	52,88	57,82	50,95	46,19
30	5	20	50	0,0004	52,50	53,00	53,46	53,46	52,53	53,67	50,69	50,69
100	5	20	50	0,0002	52,27	51,90	55,71	53,33	52,36	54,98	47,62	50,00
70	5	20	50	0,0001	52,25	52,58	53,52	54,46	51,03	57,94	50,23	46,01
50	5	20	50	0,0003	52,24	53,49	52,09	51,63	51,53	52,78	57,67	46,51
100	5	20	50	0,0003	52,18	54,29	51,43	54,29	55,50	53,55	48,10	48,10
70	5	20	50	0,0002	52,03	53,52	54,93	53,52	54,12	56,07	46,95	45,07
10	5	20	50	0,0003	52,00	53,88	50,68	53,88	51,50	55,00	49,77	49,32
10	5	20	50	0,0001	51,78	52,51	51,60	57,99	49,50	55,91	48,86	46,12
70	5	20	50	0,0004	51,71	54,46	48,36	53,99	55,67	51,40	51,17	46,95
10	5	20	50	0,0002	51,71	51,60	50,68	51,14	49,00	58,18	51,14	50,23

Tabla 6 Resultados obtenidos variando el LR y la ventana

Si bien puede considerarse en adelante probar valores mayores es importante no perder de vista que exagerar en el valor de este parámetro puede generar problemas en el proceso de entrenamiento de las redes.

Habiendo entrenado más de 600 redes diferentes el mejor modelo obtenido y resguardado hasta el momento es el siguiente:

48 horas de costo computacional

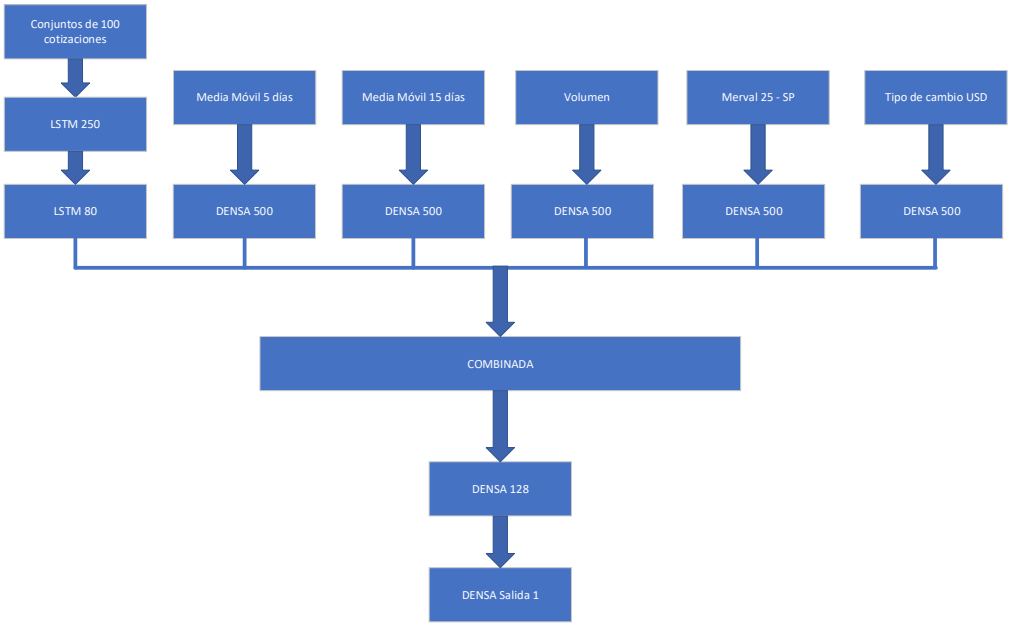

Gráfico 30 Esquema de red de 6 entradas.

Fuente: Elaboración Propia.

Ventana	**40**
Media 1	**5**
Media 2	**20**
Epochs	**500**
Promedio Pos	**55,50**
EDN	**54,17**
YPFD	**52,78**
GGAL	**53,24**
CEPU	**56,34**
CRES	**54,38**
ALUA	**61,11**
PAMP	**56,48**

Tabla 7 Resultados de modelo de 6 entradas

Con una desviación estándar de 2,8. Lo que indica una respuesta positiva al incremento del número de iteraciones logrando que ya todas las acciones superen en aciertos a los errores.

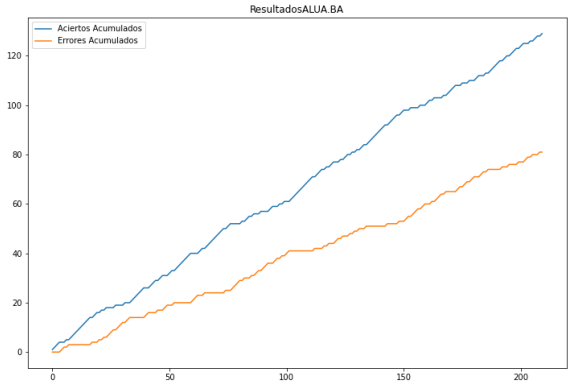

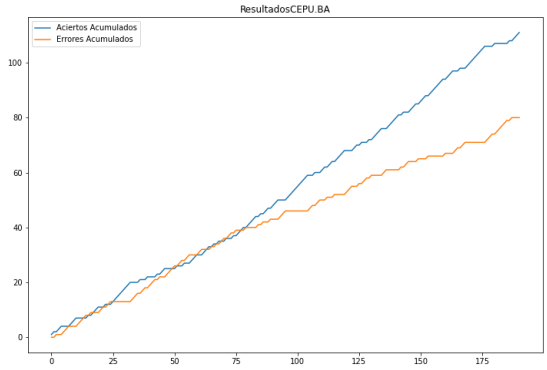

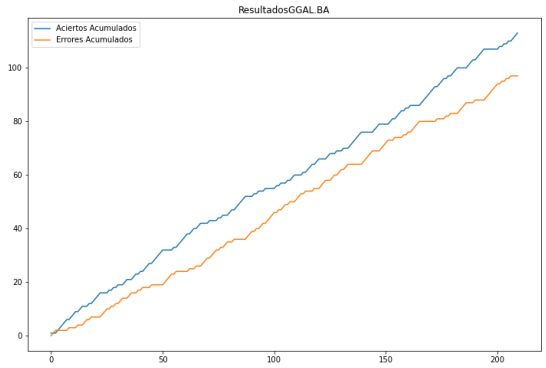

Gráfico 31 Curvas de aciertos y errores.

Fuente: Elaboración Propia.

7.8. Aplicación de series adicionales para mejorar la predicción.

Buscando favorecer la capacidad de predicción de la red se procede a incorporar series auxiliares que pudieran llegar a estar relacionadas con el comportamiento de la acción, esto se hace con la intención de establecer referencias a posibles indicadores externó que puedan colaborar con el entendimiento de la evolución de los precios de la acción estudiada.

Se consideraron las siguientes variables e indicadores:

Medias móviles:

Con el fin de aportarle al modelo la capacidad de reaccionar no solo al posible patrón presente en la ventana de precios sino también a una tendencia de los mismos se agrega a la ingesta dos medias móviles una corta y una larga (la sumatoria de pruebas empíricas realizadas arrojó como mejor resultado una media móvil corta de 5 días y una media móvil larga de 20)

Volumen:

En ocasiones cuando la acción mueve su valor con gran magnitud la existencia de un alto volumen puede llegar a tomarse como el dato que confirma que ese movimiento no se debe a una coyuntura, por eso se considera la ingesta de esta variable con la intención de sumarse a la red información respecto del potencial peso que tiene una determinada variación de precios

Índice Merval:

En ocasiones ocurren movimientos de precios que no necesariamente tienen relación directa con la acción puntual en cuestión, es decir, puede existir una suba o una baja que se debe a un comportamiento general del mercado, por eso se incorpora información sobre el índice merval para aportar en la red el estado de esa visión global dentro del mercado argentino

Tipo de Cambio del Dólar.

Un movimiento en el tipo de cambio puede generar una distorsión en los precios de las acciones, se incorpora el tipo de cambio del dólar para que la red pueda reaccionar más adecuadamente a la evolución del tipo de cambio en relación a los precios de la acción analizada

SP500:

En ocasiones los precios de las acciones se ven fuertemente afectados por movimientos que no tienen relación directa con el mercado local, por ello, para aportar una variable que intente relacionar con el factor externo, se incorpora el índice Standard and poor 500.

Cotización de la SOJA:

Una de las acciones incorporadas en los análisis pertenece a una compañía estrechamente Vinculada con el mercado agropecuario, es por eso que entendemos que la evolución de la cotización de la soja puede ser un indicador interesante para entrenar junto con esa acción.

Barril de Petróleo:

Dos de las acciones incorporadas en el estudio están vinculadas al mercado energético, paralelamente el precio del petróleo he señalado como potencial explicación de movimientos en precios de acciones por informes bursátiles en varias ocasiones. Por ello lo incorporamos como una de las variables a sumar en los entrenamientos de las redes.

7.9. Definición de la combinación de Variables definitiva.

Tomando como punto de partida una ventana de precio de 40 cotizaciones, medias móviles de 5 y 20 días y un learning rate de 0.0004. Fueron evaluados 8 casos distintos combinando la inclusión o exclusión de algunas de las variables mencionadas para corroborar que la consideración de estas incorpore o no valor al resultado obtenido por la red.

Los resultados han sido los siguientes:

Caso	1	2	3	4	5	6	7	8
Serie de Precios	Si	Si	Si	Si	Si	Si	Si	Si
Medias Móviles	X	X	Si	Si	Si	Si	Si	Si
Volumen	Si	Si	Si	Si	Si	X	Si	X
TC Dólar	Si	Si	Si	Si	X	Si	Si	Si
Merval	X	X	X	Si	Si	Si	Si	Si
SP 500	X	Si	Si	Si	Si	Si	X	X
Promedio Aciertos	51,97%	51,96%	51,63%	54,23%	53,44%	54,11%	53,26%	53,01%
Epochs	300	300	300	300	300	300	300	300
Ventana	40	40	40	40	40	40	40	40
Lr	0,0004	0,0004	0,0004	0,0004	0,0004	0,0004	0,0004	0,0004

Tabla 8 Resultados para modelos específicos por acción

Se seleccionaron 300 iteraciones entendiendo que son una combinación adecuada entre generar una red aceptablemente entrenada para poder analizar los resultados y dedicar un costo computacional aceptable.

En función de los resultados obtenidos podemos notar que el mejor modelo ha sido aquel que combina todas las variables mencionadas seguido muy de cerca por el que incluye a todas menos al SP500.

Al profundizar las iteraciones de ambos modelos, se produce una pequeña reversión obteniendo el siguiente resultado:

Caso	4	7
Serie de Precios	Si	Si
Medias Móviles	Si	Si
Volumen	Si	Si
TC Dólar	Si	Si
Merval	Si	Si
SP 500	Si	X
Promedio Aciertos	**54,89%**	**55,74%**
Epochs	700	700
Ventana	40	40
Lr	0,0004	0,0004
EDN	**51,85%**	**53,70%**
YPFD	**50,93%**	**53,24%**
GGAL	**52,31%**	**53,78%**
CEPU	**59,90%**	**59,39%**
CRES	**51,61%**	**54,38%**
ALUA	**62,04%**	**62,96%**
PAMP	**55,56%**	**53,70%**
Desv. Estándar	4,45%	3,78%

Tabla 9 Resultados incrementando las iteraciones

7.10. Análisis del costo computacional.

En el proceso de buscar el modelo más adecuado para avanzar en el chequeo concreto de la hipótesis planteada, uno de los puntos prácticos a tener en cuenta es el del costo computacional para configurar y entrenar la red que finalmente se escoja.

Sobre el costo computacional son varios los elementos que deben considerarse debido a que influyen.

Los principales elementos son:

- **Definición de la red:** La definición de la red impacta directamente en el tamaño de la misma y por ello en la cantidad de cálculos que deben propagarse. A medida que la red va creciendo se incrementan las matrices que se asocian a la misma y por ende es de esperarse un crecimiento exponencial en el costo computacional.

  Viendo este tema desde un punto de vista cualitativo, entendemos que si bien esta clara la influencia de la definición de la red sobre el costo computaciones, como esta una vez definida luego de una seria de pruebas empíricas queda como un elemento constante no se hicieron evaluaciones concretas de como estos cambios impactan concretamente en el costo computacional final.

- **Cantidad de epochs:** La cantidad de iteraciones en el entrenamiento de la red tiene una consecuencia directa en el costo computacional, en definitiva, cada epochs insume un tiempo de cálculo y el tiempo final surge de la multiplicación de ese tiempo unitario por la cantidad de iteraciones.

- **Tamaño de la ventana:** El tamaño de la ventana tiene un impacto directo en el costo computacional dado que define la unidad de cálculo por la cual se propagarán todos los cálculos y en la medida que esta unidad crezca impacta sobre los tiempos de los cálculos.

Estableciendo entonces como constante la definición de la red y sabiendo que la cantidad de epochs tiene un impacto mayormente lineal en el costo computacional, se estableció una prueba sobre la variación del único componente que queda como no necesariamente lineal y no constante (dado que debe definirse dentro del proceso de buscar mejorar el modelo) que es el tamaño de la ventana.

Se tomó 20 como valor para la cantidad de epochs y los resultados son los siguientes:

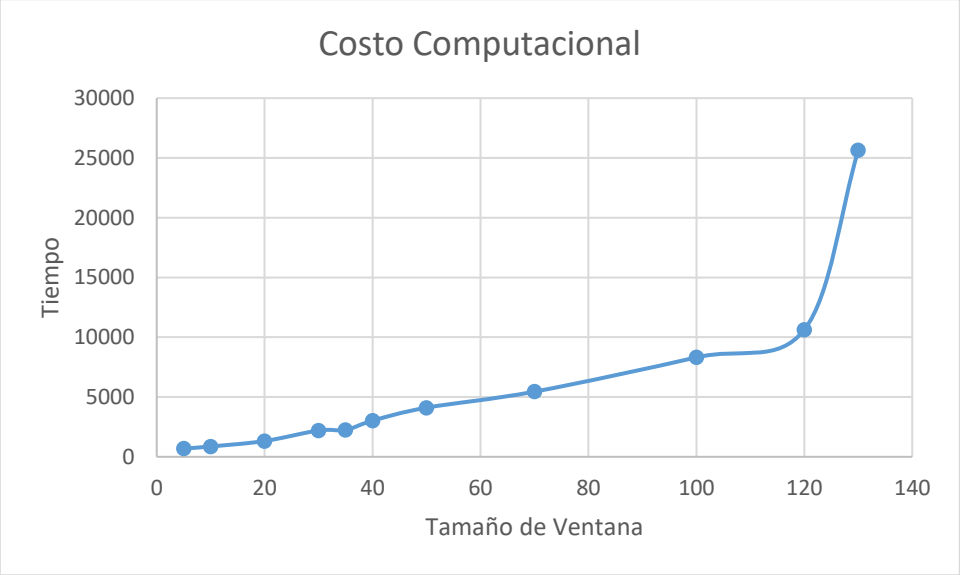

Gráfico 32 Gráfico de costo computacional en función del tamaño de ventana.

Fuente: Elaboración Propia.

Como conclusión del análisis del costo computacional encontramos que en función de la capacidad de procesamiento disponible y considerando adicionalmente los resultados de las pruebas preliminares entendemos que las ventanas adecuadas deben estar entre los valores 5 y 60 dado que a partir de 70 en adelante el costo computacional comienza a dispararse alcanzando incluso un crecimiento exponencial por encima de los 110 valores.

Habiendo evaluado el costo computacional, se ejecutó una corrida de 300 Epochs para ventanas de 5,10, 20, 25, 30, 35, 40, 50, 60, 70 y 100 precios obteniendo los siguientes resultados:

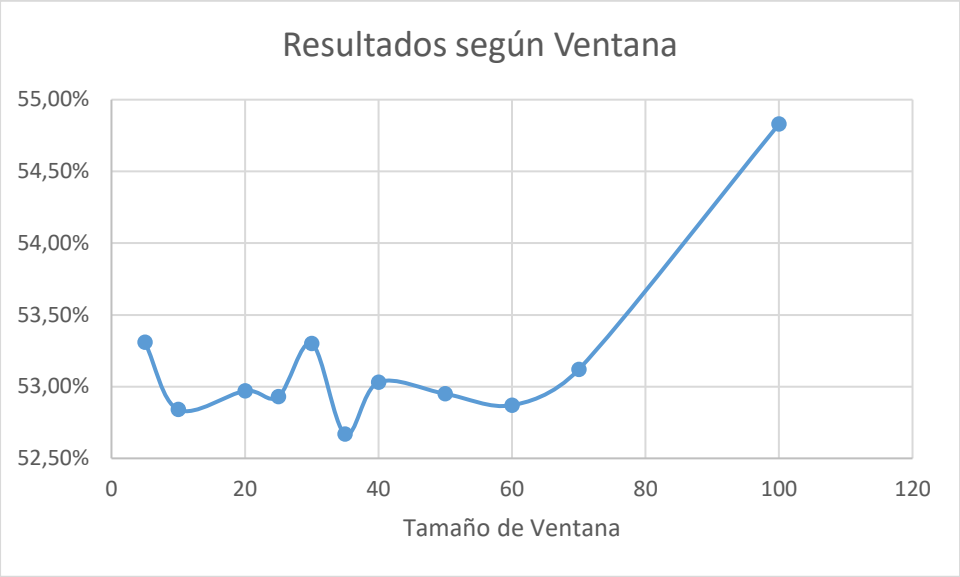

Gráfico 33 Resultados en función del tamaño de ventana.

Fuente: Elaboración propia.

El pequeño resultado favorable para la ventana de 100 cotizaciones no llega a justificar la diferencia en costo computacional.

En función de esto, encontramos como las ventanas ideales de trabajo, aquellas que están entre 10 y 60 cotizaciones.

7.11. Búsqueda del modelo principal.

En la búsqueda del modelo principal basándonos principalmente en el incremento de interacciones, ante las corridas sucesivas fuimos notando dificultades para mejorar el desempeño de estos, llegando en algunos casos incluso a que los modelos con muchas iteraciones (3000 por ejemplo) mostraban un desempeño claramente inferior a ese mismo modelo con 500 iteraciones.

Aparentemente en estos casos nos encontramos con el fenómeno del sobre entrenamiento, Para confirmar este supuesto Se creó una nueva versión del software que permite a partir de un modelo con pocas iteraciones y automáticamente ir generando cortes incrementales de iteraciones documentando los resultados.

Considerando lo que evaluamos previamente respecto del costo computacional y habiendo visto que el incremento del tamaño de la ventana de cotizaciones utilizadas no parece generar una ganancia considerable en los resultados obtenidos, para la búsqueda del modelo definitivo hemos limitado la ventana a un máximo de 60 y se ha trabajado las búsquedas iterativas en ejemplos concretos de ventana de 10 , 20, 35, 40 y 60 cotizaciones con los siguientes resultados:

Ventana de 10 cotizaciones:

Accion	Epochs Inicio	% de Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Mejor Modelo
EDN.BA	300	53,42%	500	52,97%	700	53,42%	900	53,42%	1100	53,88%	1300	53,88%	1500	**54,34%**	1700	52,51%	1900	52,05%	2100	52,51%	**54,34%**
YPFD.BA	300	46,12%	500	47,95%	700	49,77%	900	49,32%	1100	48,86%	1300	**50,23%**	1500	50,23%	1700	49,32%	1900	50,23%	2100	49,77%	**50,23%**
GGAL.BA	300	50,23%	500	52,97%	700	53,42%	900	53,42%	1100	**55,25%**	1300	54,34%	1500	54,79%	1700	53,88%	1900	54,34%	2100	54,34%	**55,25%**
CEPU.BA	300	53,00%	500	53,50%	700	**55,00%**	900	54,50%	1100	55,00%	1300	53,50%	1500	54,00%	1700	54,50%	1900	55,00%	2100	54,50%	**55,00%**
CRES.BA	300	53,18%	500	54,09%	700	53,64%	900	54,55%	1100	**55,46%**	1300	55,00%	1500	55,00%	1700	52,72%	1900	53,18%	2100	50,45%	**55,46%**
ALUA.BA	300	60,73%	500	**61,19%**	700	59,36%	900	58,90%	1100	60,27%	1300	57,99%	1500	49,77%	1700	50,22%	1900	50,68%	2100	50,22%	**61,19%**
PAMP.BA	300	52,05%	500	53,42%	700	**54,34%**	900	53,88%	1100	52,96%	1300	52,05%	1500	52,51%	1700	50,68%	1900	48,40%	2100	50,68%	**54,34%**
TXAR.BA	300	**64,75%**	500	63,14%	700	62,30%	900	62,30%	1100	61,47%	1300	61,48%	1500	61,48%	1700	62,30%	1900	61,48%	2100	61,48%	**64,75%**
TGSU2.BA	300	52,51%	500	52,05%	700	52,23%	900	52,23%	1100	52,05%	1300	52,96%	1500	54,34%	1700	**55,71%**	1900	55,71%	2100	53,42%	**55,71%**
IRSA.BA	300	52,96%	500	51,60%	700	50,68%	900	52,51%	1100	52,51%	1300	51,14%	1500	**53,42%**	1700	51,60%	1900	51,60%	2100	50,69%	**53,42%**
																					55,97%

Tabla 10 Resultados mejor modelo para Ventana de 10 Cotizaciones

Ventana de 20 Cotizaciones:

Accion	Epochs Inicio	% de Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Mejor Modelo
EDN.BA	300	55,50%	500	55,06%	700	55,06%	900	**55,96%**	1100	54,59%	1300	54,59%	1500	53,67%	1700	53,67%	1900	52,75%	2100	54,12%	**55,96%**
YPFD.BA	300	44,50%	500	47,25%	700	47,25%	900	49,08%	1100	48,62%	1300	50,00%	1500	48,62%	1700	50,91%	1900	**51,38%**	2100	50,92%	**51,38%**
GGAL.BA	300	52,75%	500	52,75%	700	54,13%	900	53,21%	1100	54,59%	1300	**55,05%**	1500	52,75%	1700	52,75%	1900	52,29%	2100	54,12%	**55,05%**
CEPU.BA	300	54,27%	500	52,26%	700	53,77%	900	53,77%	1100	53,27%	1300	55,28%	1500	52,76%	1700	52,76%	1900	53,27%	2100	**55,77%**	**55,77%**
CRES.BA	300	52,96%	500	**53,88%**	700	53,88%	900	53,42%	1100	52,51%	1300	52,51%	1500	52,51%	1700	49,31%	1900	47,03%	2100	51,60%	**53,88%**
ALUA.BA	300	60,55%	500	59,17%	700	60,09%	900	60,09%	1100	**61,00%**	1300	54,12%	1500	48,62%	1700	52,29%	1900	49,08%	2100	56,42%	**61,00%**
PAMP.BA	300	51,38%	500	52,29%	700	**55,04%**	900	54,59%	1100	51,83%	1300	53,67%	1500	51,83%	1700	51,37%	1900	50,46%	2100	50,92%	**55,04%**
TXAR.BA	300	55,81%	500	56,28%	700	57,21%	900	**58,14%**	1100	58,14%	1300	54,88%	1500	51,63%	1700	57,21%	1900	56,74%	2100	53,02%	**58,14%**
TGSU2.BA	300	50,92%	500	52,05%	700	50,22%	900	52,05%	1100	52,97%	1300	54,34%	1500	**55,71%**	1700	55,71%	1900	53,42%	2100	53,42%	**55,71%**
IRSA.BA	300	50,92%	500	51,60%	700	50,68%	900	52,51%	1100	52,51%	1300	51,14%	1500	**53,42%**	1700	51,60%	1900	51,60%	2100	50,69%	**53,42%**
																					55,54%

Tabla 11 Resultados mejor modelo para Ventana de 20 Cotizaciones

Ventana de 35 Cotizaciones:

Accion	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Mejor Modelo
EDN.BA	600	52,78%	800	52,78%	900	53,24%	1600	55,56%	1800	53,70%	1900	**56,02%**	2100	54,17%	2200	54,63%	2800	56,02%	**56,02%**
YPFD.BA	600	49,77%	800	48,39%	900	49,31%	1600	51,61%	1800	54,84%	1900	53,00%	2100	**58,53%**	2200	56,22%	2800	55,30%	**58,53%**
GGAL.BA	600	52,54%	800	53,46%	900	53,00%	1600	52,53%	1800	54,38%	1900	54,84%	2100	53,46%	2200	**55,30%**	2800	53,46%	**55,30%**
CEPU.BA	600	51,01%	800	51,01%	900	50,00%	1600	50,00%	1800	54,04%	1900	54,55%	2100	53,03%	2200	52,02%	2800	**56,06%**	**56,06%**
CRES.BA	600	52,07%	800	52,07%	900	52,07%	1600	51,15%	1800	**57,14%**	1900	51,61%	2100	49,76%	2200	52,07%	2800	49,31%	**57,14%**
ALUA.BA	600	59,91%	800	**61,75%**	900	60,83%	1600	52,53%	1800	52,07%	1900	52,07%	2100	53,00%	2200	51,61%	2800	55,76%	**61,75%**
PAMP.BA	600	53,24%	800	53,24%	900	**55,56%**	1600	51,85%	1800	50,93%	1900	50,93%	2100	52,31%	2200	49,54%	2800	51,39%	**55,56%**
TXAR.BA	600	**58,69%**	800	53,99%	900	52,58%	1600	52,58%	1800	47,89%	1900	49,77%	2100	50,23%	2200	48,36%	2800	52,58%	**58,69%**
TGSU2.BA	600	52,07%	800	53,00%	900	53,00%	1600	**57,60%**	1800	53,92%	1900	55,76%	2100	50,23%	2200	52,07%	2800	51,61%	**57,60%**
IRSA.BA	600	52,31%	800	50,93%	900	52,78%	1600	**58,80%**	1800	54,17%	1900	49,54%	2100	49,54%	2200	47,22%	2800	56,01%	**58,80%**
																			57,55%

Tabla 12 Resultados mejor modelo para Ventana de 35 Cotizaciones

Ventana de 40 Cotizaciones:

Accion	Epochs Inicio	% de Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Mejor Modelo
EDN.BA	300	51,38%	500	**54,16%**	700	54,16%	900	53,70%	1100	51,85%	1300	53,70%	1500	52,78%	1700	49,07%	1900	51,39%	2100	51,85%	**54,16%**
YPFD.BA	300	51,85%	500	50,46%	700	51,39%	900	53,70%	1100	53,24%	1300	**56,94%**	1500	55,09%	1700	51,85%	1900	53,24%	2100	55,09%	**56,94%**
GGAL.BA	300	53,24%	500	52,78%	700	54,17%	900	53,70%	1100	53,70%	1300	52,31%	1500	52,31%	1700	**54,63%**	1900	53,70%	2100	52,78%	**54,63%**
CEPU.BA	300	57,87%	500	58,38%	700	**60,40%**	900	59,39%	1100	56,34%	1300	57,87%	1500	56,85%	1700	53,81%	1900	54,31%	2100	56,35%	**60,40%**
CRES.BA	300	**55,30%**	500	54,38%	700	51,61%	900	52,07%	1100	53,46%	1300	54,38%	1500	51,15%	1700	50,69%	1900	49,78%	2100	50,69%	**55,30%**
ALUA.BA	300	59,72%	500	58,80%	700	57,40%	900	61,11%	1100	**62,03%**	1300	58,33%	1500	57,87%	1700	60,18%	1900	56,48%	2100	55,55%	**62,03%**
PAMP.BA	300	54,17%	500	50,93%	700	52,78%	900	53,70%	1100	**56,02%**	1300	55,09%	1500	54,17%	1700	48,14%	1900	52,77%	2100	53,24%	**56,02%**
TXAR.BA	300	55,87%	500	56,61%	700	56,81%	900	49,30%	1100	53,05%	1300	50,23%	1500	53,52%	1700	45,54%	1900	50,70%	2100	**57,75%**	**57,75%**
TGSU2.BA	300	**54,63%**	500	51,85%	700	45,83%	900	52,31%	1100	49,53%	1300	53,70%	1500	51,85%	1700	52,31%	1900	53,24%	2100	53,24%	**54,63%**
IRSA.BA	300	51,85%	500	53,24%	700	52,31%	900	49,54%	1100	51,85%	1300	51,85%	1500	54,63%	1700	54,17%	1900	**55,09%**	2100	51,38%	**55,09%**
																					56,70%

Tabla 13 Resultados mejor modelo para Ventana de 40 Cotizaciones

Ventana de 60 Cotizaciones:

Accion	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Epochs	% Aciertos	Mejor Modelo
EDN.BA	500	50,47%	700	**54,67%**	900	54,21%	1100	53,74%	1300	51,40%	1500	51,87%	1700	51,87%	1900	51,87%	2100	50,47%	**54,67%**
YPFD.BA	500	52,80%	700	50,00%	900	50,93%	1100	54,67%	1300	**55,14%**	1500	52,80%	1700	54,67%	1900	55,14%	2100	53,74%	**55,14%**
GGAL.BA	500	52,80%	700	51,87%	900	51,40%	1100	54,67%	1300	**55,14%**	1500	53,27%	1700	53,74%	1900	51,87%	2100	51,40%	**55,14%**
CEPU.BA	500	59,49%	700	57,95%	900	**60,00%**	1100	55,38%	1300	56,92%	1500	55,38%	1700	55,90%	1900	55,38%	2100	53,33%	**60,00%**
CRES.BA	500	**56,28%**	700	50,70%	900	52,09%	1100	51,16%	1300	54,42%	1500	52,09%	1700	54,88%	1900	55,34%	2100	52,56%	**56,28%**
ALUA.BA	500	**61,21%**	700	61,68%	900	55,61%	1100	56,07%	1300	57,01%	1500	51,87%	1700	53,27%	1900	50,93%	2100	53,74%	**61,68%**
PAMP.BA	500	**54,21%**	700	51,87%	900	43,73%	1100	49,07%	1300	50,47%	1500	51,87%	1700	43,46%	1900	50,00%	2100	50,93%	**54,21%**
TXAR.BA	500	**60,66%**	700	55,92%	900	57,35%	1100	53,08%	1300	54,50%	1500	52,61%	1700	54,03%	1900	54,03%	2100	51,18%	**60,66%**
TGSU2.BA	500	52,34%	700	50,93%	900	**55,14%**	1100	50,94%	1300	52,34%	1500	52,34%	1700	50,47%	1900	50,93%	2100	50,47%	**55,14%**
IRSA.BA	500	50,93%	700	51,40%	900	48,60%	1100	**54,21%**	1300	51,40%	1500	54,20%	1700	49,53%	1900	45,79%	2100	48,59%	**54,21%**
																			56,71%

Tabla 14 Resultados mejor modelo para Ventana de 60 Cotizaciones

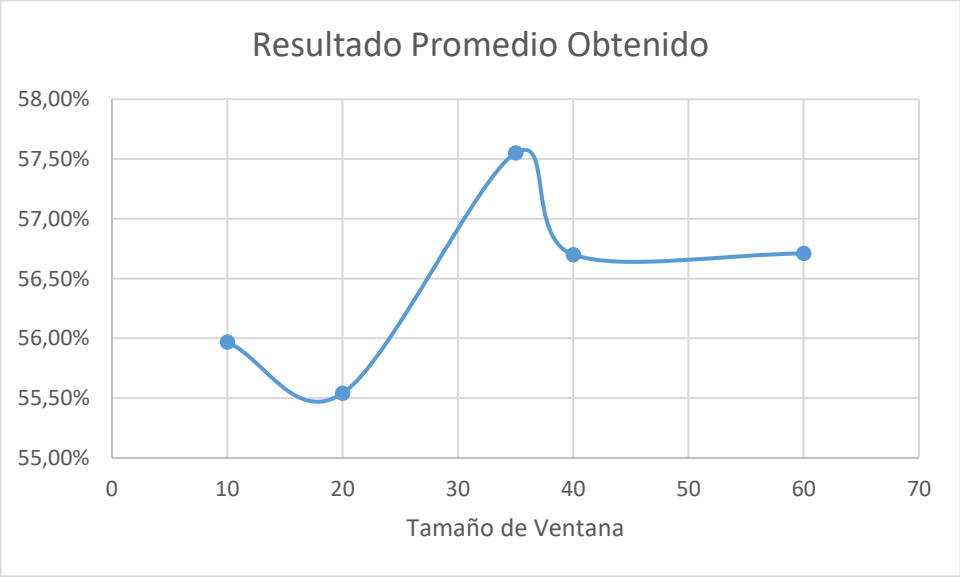

Gráfico 34 Curva de resultados promedios obtenidos en función de la ventana.

Fuente: Elaboración Propia.

Los dos mejores modelos obtenidos han sido aquellos con ventanas de 35 y 40 cotizaciones, los cuales adicionalmente se encuentran dentro del marco de lo alcanzable en cuanto a capacidad de cómputo.

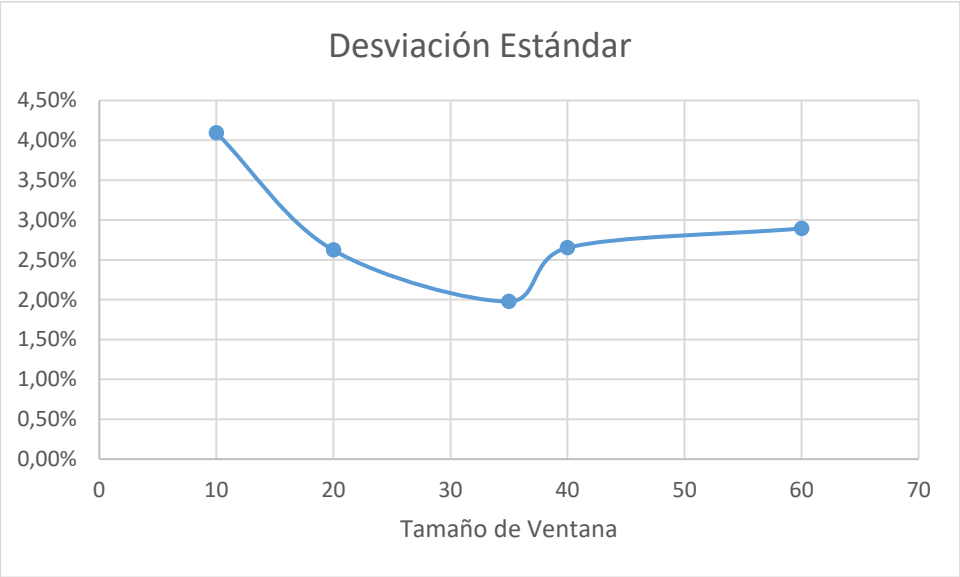

Gráfico 35 Desviación estándar de los resultados en función de la ventana.

Fuente: Elaboración propia

El modelo que mayor performance logró fue también el de menor desviación estándar tuvo, por lo cual seleccionamos como modelo principal aquel con una ventana de 35 precios.

7.12. Modelo definitivo.

Habiendo encontrado el mecanismo para trabajar en la búsqueda del modelo definitivo, y entendiendo que cada acción tratada implica el entrenamiento de una red neuronal separada. Se comenzó a entrenar por separado las redes correspondientes a las diferentes acciones ya sin imponer una cantidad específica de epochs dado que las diferentes redes caen en sobreentrenamiento en momentos diferentes.

Para ello se creó un código fuente diferente el cual a partir de un modelo inicial de 300 epochs iteraba entrenamientos de 100 epochs adicionales y verificaba los datos así sucesivamente hasta llegar al sobreentrenamiento.

Como era esperado los rendimientos máximos para cada acción fueron encontrados en diferentes cantidades de epochs, logrando así maximizar el rendimiento promedio del modelo.

Tomando como base una ventana de 35 cotizaciones se obtuvo el siguiente resultado:

Accion	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Ep	% Aciertos	Mejor Modelo
EDN.BA	600	52,78%	800	52,78%	900	53,24%	1600	55,56%	1800	53,70%	1900	**56,02%**	2100	54,17%	2200	54,63%	2800	56,02%	**56,02%**
YPFD.BA	600	49,77%	800	48,39%	900	49,31%	1600	51,61%	1800	54,84%	1900	53,00%	2100	**58,53%**	2200	56,22%	2800	55,30%	**58,53%**
GGAL.BA	600	52,54%	800	53,46%	900	53,00%	1600	52,53%	1800	54,38%	1900	54,84%	2100	53,46%	2200	**55,30%**	2800	53,46%	**55,30%**
CEPU.BA	600	51,01%	800	51,01%	900	50,00%	1600	50,00%	1800	54,04%	1900	54,55%	2100	53,03%	2200	52,02%	2800	**56,06%**	**56,06%**
CRES.BA	600	52,07%	800	52,07%	900	52,07%	1600	51,15%	1800	**57,14%**	1900	51,61%	2100	49,76%	2200	52,07%	2800	49,31%	**57,14%**
ALUA.BA	600	59,91%	800	**61,75%**	900	60,83%	1600	52,53%	1800	52,07%	1900	52,07%	2100	53,00%	2200	51,61%	2800	55,76%	**61,75%**
PAMP.BA	600	53,24%	800	53,24%	900	**55,56%**	1600	51,85%	1800	50,93%	1900	50,93%	2100	52,31%	2200	49,54%	2800	51,39%	**55,56%**
TXAR.BA	600	**58,69%**	800	53,99%	900	52,58%	1600	52,58%	1800	47,89%	1900	49,77%	2100	50,23%	2200	48,36%	2800	52,58%	**58,69%**
TGSU2.BA	600	52,07%	800	53,00%	900	53,00%	1600	**57,60%**	1800	53,92%	1900	55,76%	2100	50,23%	2200	52,07%	2800	51,61%	**57,60%**
IRSA.BA	600	52,31%	800	50,93%	900	52,78%	1600	**58,80%**	1800	54,17%	1900	49,54%	2100	49,54%	2200	47,22%	2800	56,01%	**58,80%**
																			57,55%

Tabla 15 Mejor modelo encontrado

Este modelo alcanzó una desviación estándar por acción del 1,98%

El detalle de las combinaciones de variables utilizadas es el siguiente:

Acción	Caso
EDN.BA	7
YPFD.BA	7
GGAL.BA	4
CEPU.BA	10
CRES.BA	11
ALUA.BA	10
PAMP.BA	4
TXAR.BA	8
TGSU2.BA	4
IRSA.BA	4

Caso	1	2	3	4	5	6	7	8	9	10	11
Serie de Precios	Si	Si	Si	Si	Si	Si	Si	Si	Si	Si	Si
Medias Móviles	X	X	Si	Si	Si	Si	Si	Si	Si	Si	Si
Volumen	Si	Si	Si	Si	Si	X	Si	X	Si	Si	Si
TC Dólar	Si	Si	Si	Si	X	Si	Si	Si	Si	Si	Si
Merval	X	X	X	Si	Si	Si	Si	Si	Si	Si	Si
SP 500	X	Si	Si	Si	Si	Si	X	X	Si	X	X
Petroleo Brent	X	X	X	X	X	X	X	X	Si	Si	X
Soja	X	X	X	X	X	X	X	X	X	X	Si

Tabla 16 Casos utilizados para el mejor modelo

7.13. Evaluación de la Hipótesis

Habiendo seleccionado el mejor modelo y teniendo ya los resultados arrojados por dicho modelo en el período de tiempo seleccionado (agosto 2020 a Julio 2021), procedemos a evaluar cualitativamente los datos obtenidos.

Tenemos los siguientes resultados acción por acción:

	TXAR.BA	IRSA.BA	TGSU2.BA	PAMP.BA	ALUA.BA	CRES.BA	CEPU.BA	GGAL.BA	YPFD.BA	EDN.BA	Promedio Mes a Mes	Dif promedio aciertos
ago-20		37,50%	47,06%	50,00%	53,00%	52,94%		64,71%	53,00%	50,00%	51,03%	
sep-20		54,55%	45,45%	50,00%	74,00%	72,73%	45,00%	59,09%	68,00%	63,64%	59,16%	15,94%
oct-20	71,43%	80,95%	66,67%	57,14%	71,00%	66,67%	52,38%	66,67%	57,00%	71,43%	66,13%	11,78%
nov-20	54,17%	65,00%	45,00%	65,00%	70,00%	45,00%	40,00%	55,00%	40,00%	35,00%	51,42%	-22,25%
dic-20	43,48%	55,56%	72,22%	61,11%	44,00%	44,44%	44,44%	50,00%	44,00%	55,56%	51,48%	0,13%
ene-21	50,00%	45,00%	65,00%	57,89%	60,00%	60,00%	65,00%	35,00%	60,00%	60,00%	55,79%	8,37%
feb-21	40,91%	61,11%	61,11%	52,63%	56,00%	55,56%	66,67%	50,00%	72,00%	61,11%	57,71%	3,44%
mar-21	81,48%	68,18%	54,55%	54,55%	73,00%	59,09%	63,64%	50,00%	59,00%	40,91%	60,44%	4,73%
abr-21	65,22%	55,00%	70,00%	55,00%	40,00%	45,00%	65,00%	60,00%	70,00%	45,00%	57,02%	-5,65%
may-21	62,50%	63,16%	52,63%	52,63%	63,00%	52,63%	63,16%	63,16%	74,00%	73,68%	62,06%	8,83%
jun-21	56,00%	55,00%	55,00%	55,00%	70,00%	70,00%	55,00%	55,00%	45,00%	60,00%	57,60%	-7,18%
Promedio	58,35%	58,27%	57,70%	55,54%	61,27%	56,73%	56,03%	55,33%	58,36%	56,03%	57,26%	1,81%
Máximo	81,48%	80,95%	72,22%	65,00%	74,00%	72,73%	66,67%	66,67%	74,00%	73,68%	66,13%	15,94%
Mínimo	40,91%	37,50%	45,00%	50,00%	40,00%	44,44%	40,00%	35,00%	40,00%	35,00%	51,03%	-22,25%
Dev Estándar	13,17%	11,58%	9,87%	4,57%	11,82%	10,03%	10,06%	9,01%	11,89%	12,22%	4,74%	11,16%

Tabla 17 Resultados de las predicciones mes a mes

Partiendo de los valores arrojados mes a mes por el modelo a partir del promedio de los resultados de todas las acciones, que son los siguientes:

	Promedio Mes a Mes	Dif mensual del promedio aciertos
ago-20	**51,03%**	
sep-20	**59,16%**	**15,94%**
oct-20	**66,13%**	**11,78%**
nov-20	**51,42%**	**-22,25%**
dic-20	**51,48%**	**0,13%**
ene-21	**55,79%**	**8,37%**
feb-21	**57,71%**	**3,44%**
mar-21	**60,44%**	**4,73%**
abr-21	**57,02%**	**-5,65%**
may-21	**62,06%**	**8,83%**
jun-21	**57,60%**	**-7,18%**
Promedio	**57,26%**	**1,81%**
Máximo	**66,13%**	**15,94%**
Mínimo	**51,03%**	**-22,25%**
Dev Estándar	**4,74%**	**11,16%**

Tabla 18 Promedios mes a mes de predicciones

Para decidir la correlación entre las variables hemos utilizado el coeficiente de correlación de Pearson, considerando correlación fuerte a aquellos valores que en valor absoluto superan 0,40 y existencia de correlación a los que en valor absoluto superan 0,30.

Tomando como referencia los promedios mensuales de aciertos arrojados por el modelo cuando comparamos estos valores con el desempeño de las variables macroeconómicas seleccionadas obtenemos los siguientes resultados:

	Promedio Mes a Mes
Variacion % TC	**-0,592314586**
Variación % Tasa	**-0,445501434**
Base Monetaria	0,301125291
Variacion % RP	-0,298317208
Depositos	0,286186891
CER	0,265534771
TC	0,236347613
Variacion % CER	0,149533888
Variacion % B.M	-0,135952531
Riesgo Pais	-0,128421687
Variacion % CCL	0,081775567
CCL	0,070002299
Tasa	0,065616664
Variacion % Depositos	-0,025350371

Tabla 19 Correlaciones obtenidas para los promedios mes a mes

La mayor correlación hallada para los promedios mensuales de aciertos ha sido una correlación inversa con la variación en porcentaje del tipo de cambio oficial, el índice de correlación de Pearson entre el promedio de aciertos mensuales y la variación en porcentaje del tipo de cambio fue de -**0.59231459**, marcando una alta correlación inversa.

	Promedio Mes a Mes	TC	Variacion % TC
ago-20	51,03%	76,39	7,956%
sep-20	59,16%	78,5	2,762%
oct-20	66,13%	80,8	2,930%
nov-20	51,42%	84,41	4,468%
dic-20	51,48%	86,95	3,009%
ene-21	55,79%	90,22	3,761%
feb-21	57,71%	92,99	3,070%
mar-21	60,44%	95,51	2,710%
abr-21	57,02%	98,01	2,618%
may-21	62,06%	99,15	1,163%
jun-21	57,60%	100,16	1,019%
Promedio	57,26%	89,37	3,22%
Máximo	66,13%	100,16	7,96%
Mínimo	51,03%	76,39	1,02%
Dev Estándar	4,74%	8,54	1,85%

Tabla 20 Análisis de valores correlacionados con el porcentaje de variación del TC

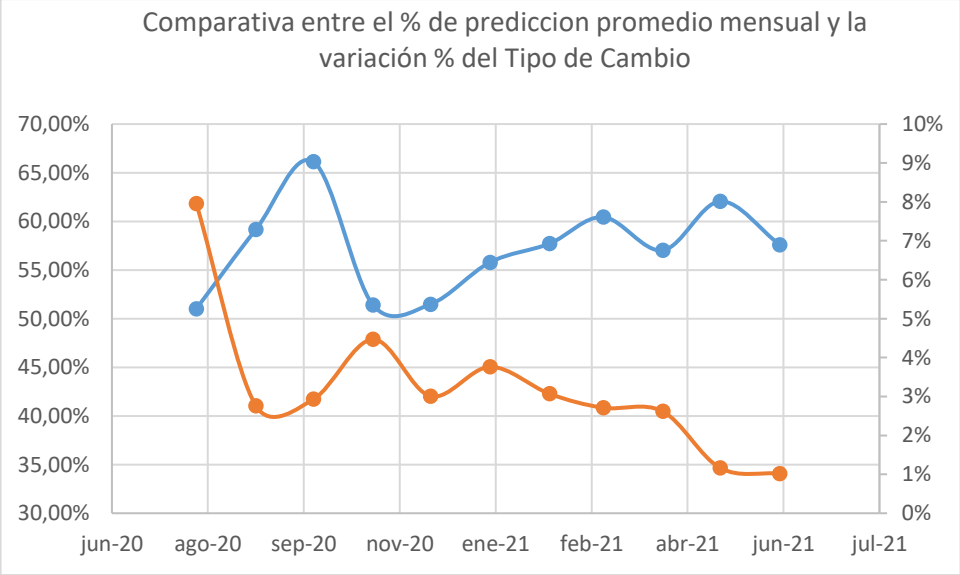

Gráfico 36 Comparativa de predicción promedio vs Variación porcentual del Tipo de Cambio.

Fuente: Elaboración Propia.

En segundo orden, se halló una correlación inversa entre los porcentajes de acierto mes a mes y la variación porcentual de la Tasa. En este caso el índice de correlación de Pearson entregó un valor de **-0,445501434** marcando una alta correlación inversa.

	Promedio Mes a Mes	Tasa	Variación % Tasa
ago-20	51,03%	25,70%	3%
sep-20	59,16%	27,50%	7,00%
oct-20	66,13%	28,10%	2,18%
nov-20	51,42%	30,10%	7,12%
dic-20	51,48%	32,50%	7,97%
ene-21	55,79%	32,20%	-0,92%
feb-21	57,71%	33,20%	3,11%
mar-21	60,44%	32,90%	-0,90%
abr-21	57,02%	32,30%	-1,82%
may-21	62,06%	32,10%	-0,62%
jun-21	57,60%	32,80%	2,18%
Promedio	**57,26%**	**30,85%**	**2,55%**
Máximo	**66,13%**	**33,20%**	**7,97%**
Mínimo	**51,03%**	**25,70%**	**-1,82%**
Dev Estándar	**4,74%**	**2,60%**	**3,52%**

Tabla 21 Comparativa entre los aciertos promedio mensuales y la variación porcentual de la tasa

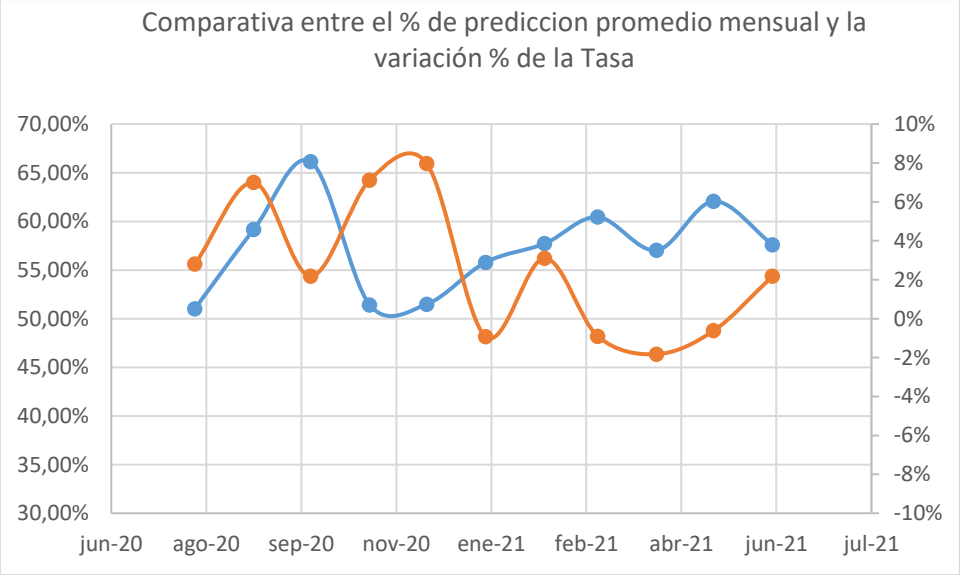

Gráfico 37 Curvas comparativas de promedios de aciertos mensuales vs la variación porcentual de tasa.

Fuente: Elaboración Propia.

Se hallo una correlación positiva entre los promedios mensuales de aciertos y la base monetaria. En este caso el índice de correlación de Pearson arrojó un valor de **0,301125291**.

	Promedio Mes a Mes	Base Monetaria
ago-20	51,03%	2.428.900
sep-20	59,16%	2.287.225
oct-20	66,13%	2.393.695
nov-20	51,42%	2.225.061
dic-20	51,48%	2.227.275
ene-21	55,79%	2.470.260
feb-21	57,71%	2.481.310
mar-21	60,44%	2.408.886
abr-21	57,02%	2.432.295
may-21	62,06%	2.370.115
jun-21	57,60%	2.517.197
Promedio	**57,26%**	**2.385.656**
Máximo	**66,13%**	**2.517.197**
Mínimo	**51,03%**	**2.225.061**
Dev Estándar	**4,74%**	**99.532**

Tabla 22 Comparación de los promedios de aciertos mensuales y la evolución de la base monetaria

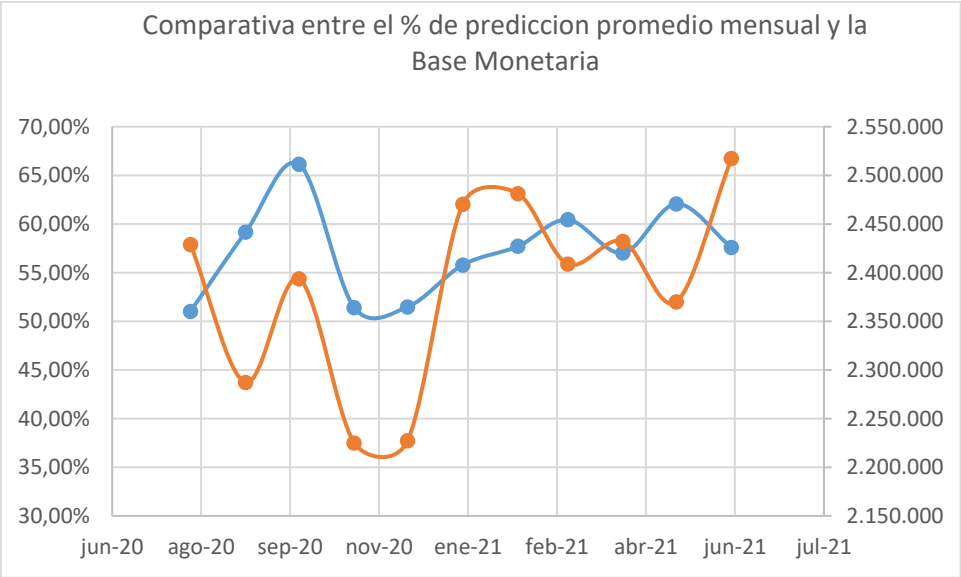

Gráfico 38 Curva comparativa entre los promedios mensuales de aciertos y la Base Monetaria.

Fuente: Elaboración Propia.

En la comparación contra el promedio mes a mes siguiendo en escala descendente por valor absoluto del coeficiente de correlación de Pearson encontramos algún grado de correlación inversa con la variación en porcentaje del Riesgo País

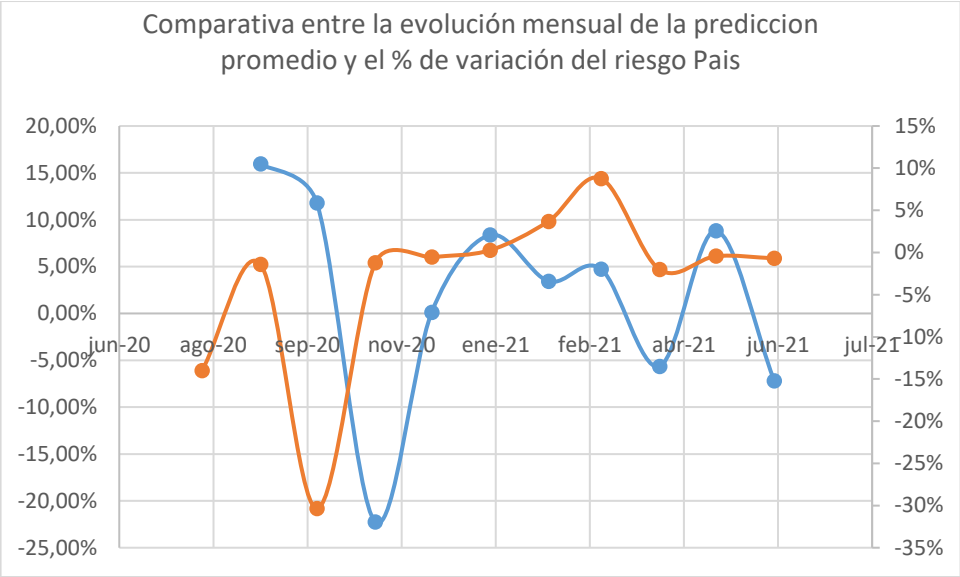

Gráfico 39 Comparativa entre la evolución de la predicción promedio y el porcentaje de variación del Riesgo País.

Fuente: Elaboración Propia.

Siguiendo en orden descendente, encontramos algún grado de correlación directa con el total de depósitos, obteniendo un coeficiente de correlación de Pearson de 0,286186891 y con el coeficiente de estabilización de referencia (CER) alcanzando un coeficiente de correlación de 0,265534771.

El otro enfoque analizado es el diferencial mes a mes de los promedios de las predicciones.

	Promedio Mes a Mes	Dif mensual del promedio aciertos
ago-20	51,03%	
sep-20	59,16%	15,94%
oct-20	66,13%	11,78%
nov-20	51,42%	-22,25%
dic-20	51,48%	0,13%
ene-21	55,79%	8,37%
feb-21	57,71%	3,44%
mar-21	60,44%	4,73%
abr-21	57,02%	-5,65%
may-21	62,06%	8,83%
jun-21	57,60%	-7,18%
Promedio	57,26%	1,81%
Máximo	66,13%	15,94%
Mínimo	51,03%	-22,25%
Dev Estándar	4,74%	11,16%

Tabla 23 Promedios de aciertos mes a mes y diferenciales mes a mes, Fuente: Elaboración Propia.

Tomando como punto de comparación las diferencias mes a mes de los promedios de aciertos y contrastándolo contra las evoluciones de las mismas variables ya analizadas, encontramos los siguientes índices de correlación de Pearson ordenados por sus valores absolutos de forma descendente:

	Dif Mensual de Promedio de Aciertos
CCL	-0,542835286
Riesgo Pais	0,44025603
Variacion % Depositos	0,325046291
Tasa	-0,291355264
Variacion % CER	-0,269450787
Variacion % TC	-0,262175958
Variacion % RP	-0,231506823
TC	-0,229572951
Variación % Tasa	-0,209294293
Variacion % B.M	0,208484401
CER	-0,200942978
Base Monetaria	0,187884311
Depositos	-0,15573545
Variacion % CCL	-0,124369711

Tabla 24 Correlaciones halladas para los diferenciales en porcentaje de los promedios de aciertos mes a mes

La mayor correlación encontrada para los diferenciales mes a mes de los promedios de aciertos es una correlación inversa con el Contado con Liquidación, en este caso el coeficiente de correlación de Pearson nos dio una correlación inversa de **-0,542835286**.

	Dif mensual del promedio aciertos	CCL
ago-20		104,1
sep-20	15,94%	124,1
oct-20	11,78%	125,84
nov-20	-22,25%	145,65
dic-20	0,13%	147,7
ene-21	8,37%	148,04
feb-21	3,44%	140,26
mar-21	4,73%	150,52
abr-21	-5,65%	145,32
may-21	8,83%	147,18
jun-21	-7,18%	155,64
Promedio	**1,81%**	**143,03**
Máximo	**15,94%**	**155,64**
Mínimo	**-22,25%**	**124,10**
Dev Estándar	**11,16%**	**10,29**

Tabla 25 Correlación entre los diferenciales de los promedios de aciertos mes a mes y el Contado con Liquidación

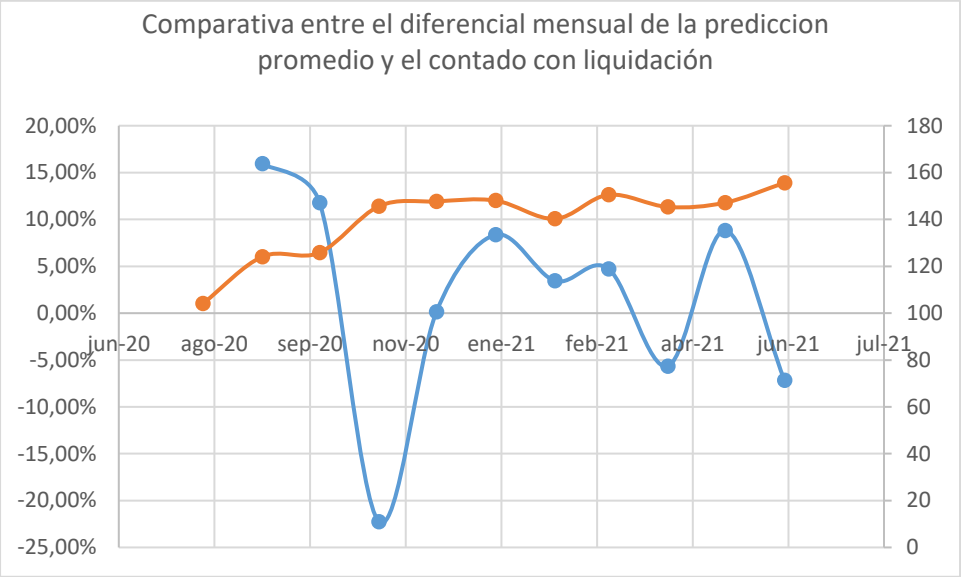

Gráfico 40 Curvas comparativas entre el diferencial mensual de las predicciones promedio y el contado con liquidación.

Fuente: Elaboración Propia.

En segundo lugar, encontramos una correlación directa con el Riesgo País. En este caso el coeficiente de correlación de Pearson vale **0,44025603** siendo compatible con un nivel importante de correlación.

	Dif mensual del promedio aciertos	Riesgo Pais
ago-20		2.158
sep-20	15,94%	2.128
oct-20	11,78%	1.482
nov-20	-22,25%	1.464
dic-20	0,13%	1.456
ene-21	8,37%	1.460
feb-21	3,44%	1.514
mar-21	4,73%	1.647
abr-21	-5,65%	1.614
may-21	8,83%	1.607
jun-21	-7,18%	1.596
Promedio	**1,81%**	**1.597**
Máximo	**15,94%**	**2.128**
Mínimo	**-22,25%**	**1.456**
Dev Estándar	**11,16%**	**200**

Tabla 26 Correlación entre los diferenciales de los promedios de aciertos mes a mes y el Riesgo País

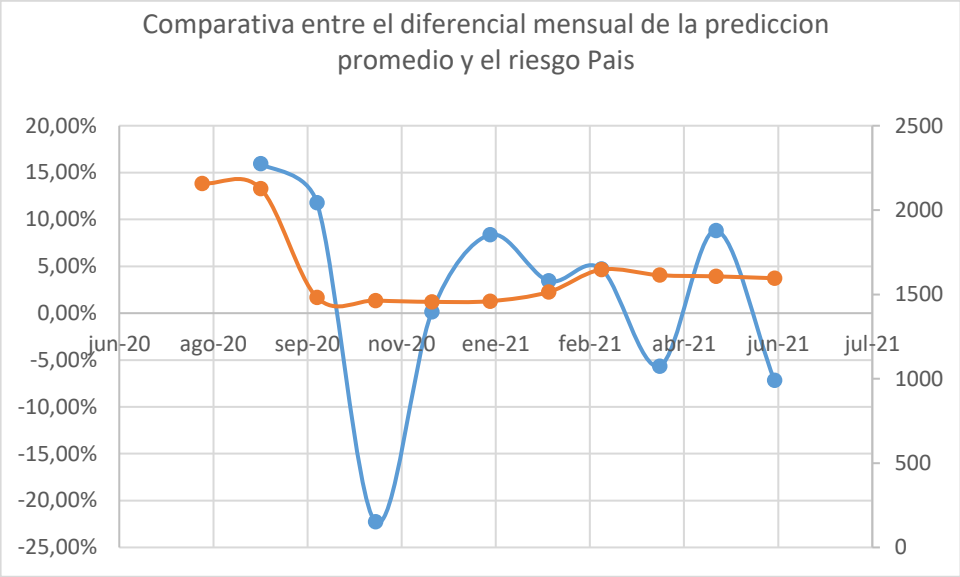

Gráfico 41 Curva comparativa entre el diferencial mensual de la predicción promedio y el riesgo país.

Fuente: Elaboración Propia.

Siguiendo el orden descendente encontramos un grado de correlación positiva entre los diferenciales mes a mes de los promedios de aciertos y las variaciones en porcentajes mes a mes de los depósitos totales en el sistema bancario, en este caso el coeficiente de correlación de Pearson arrojó un valor de **0,325046291**.

	Dif mensual del promedio aciertos	Depositos	Variacion % Depositos
ago-20		5437244	3%
sep-20	**15,94%**	5583244	3%
oct-20	**11,78%**	5711854	2%
nov-20	**-22,25%**	5782227	1%
dic-20	**0,13%**	6067454	5%
ene-21	**8,37%**	6320151	4%
feb-21	**3,44%**	6451529	2%
mar-21	**4,73%**	6739011	4%
abr-21	**-5,65%**	7019008	4%
may-21	**8,83%**	7332373	4%
jun-21	**-7,18%**	7544258	3%
Promedio	**1,81%**	**6.455.111**	**3%**
Máximo	**15,94%**	**7.544.258**	**5%**
Mínimo	**-22,25%**	**5.583.244**	**1%**
Dev Estándar	**11,16%**	**690.271**	**1%**

Tabla 27 Correlación entre los diferenciales de los promedios de aciertos mes a mes y la variación porcentual de los depósitos de privados

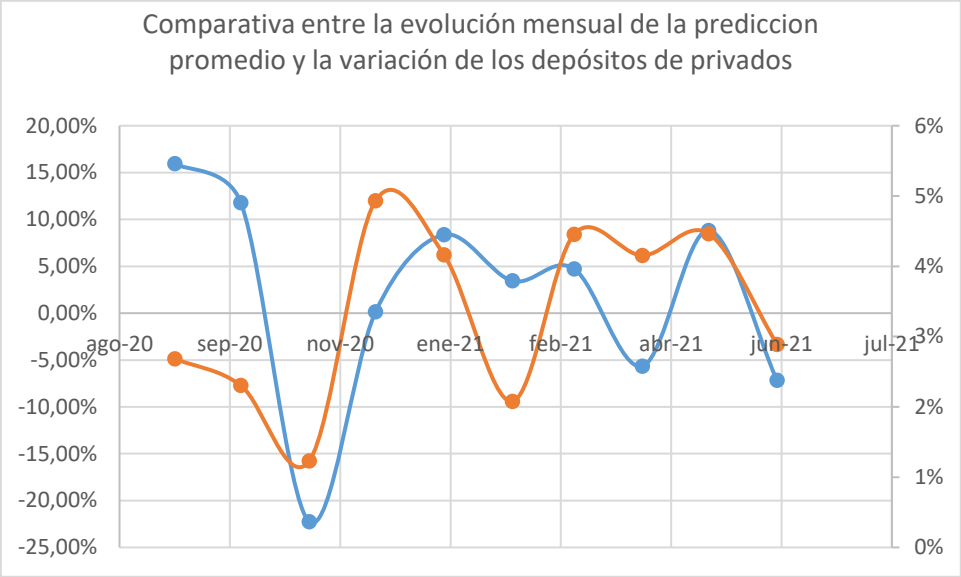

Gráfico 42 Curva comparativa entre la evolución mensual de la predicción promedio y la variación porcentual de los depósitos de privados.

Fuente: Elaboración Propia.

Por último, se percibe cierto grado de correlación inversa entre las variaciones porcentuales mes a mes de los promedios de aciertos y la Tasa, con un coeficiente de correlación de Pearson de -0,291355264, la variación porcentual del tipo de cambio con una correlación inversa de -0,262175958 y la variación porcentual del CER con una correlación inversa de -0,269450787.

Tabla de correlaciones halladas:

	Promedio Mes a Mes	*Dif promedio aciertos*
CER	0,265534771	-0,200942978
Variacion % CER	0,149533888	-0,269450787
TC	0,236347613	-0,229572951
Variacion % TC	**-0,592314586**	-0,262175958
Riesgo Pais	-0,128421687	**0,44025603**
Variacion % RP	-0,298317208	-0,231506823
Base Monetaria	0,301125291	0,187884311
Variacion % B.M	-0,135952531	0,208484401
Tasa	0,065616664	-0,291355264
Variación % Tasa	**-0,445501434**	-0,209294293
Depositos	0,286186891	-0,15573545
Variacion % Depositos	-0,025350371	0,325046291
CCL	0,070002299	**-0,542835286**
Variacion % CCL	0,081775567	-0,124369711

Tabla 28 Resumen de correlaciones halladas

Abriendo el análisis por acción, podemos ver rápidamente que las correlaciones no resultan ser homogéneas. Si tomamos como ejemplo el caso de la mejor correlación encontrada entre el promedio de aciertos y la variación mes a mes del tipo de cambio, viendo esto acción por acción obtenemos los siguientes coeficientes de correlación.

	Variacion % TC
TXAR.BA	-0,233088053
IRSA.BA	-0,502592956
TGSU2.BA	-0,285828724
PAMP.BA	-0,045218582
ALUA.BA	-0,224194112
CRES.BA	-0,286118447
CEPU.BA	-0,317846828
GGAL.BA	0,086478028
YPFD.BA	-0,274680885
EDN.BA	-0,406091547

Tabla 29 Correlaciones acción por acción versus la variación porcentual del Tipo de Cambio

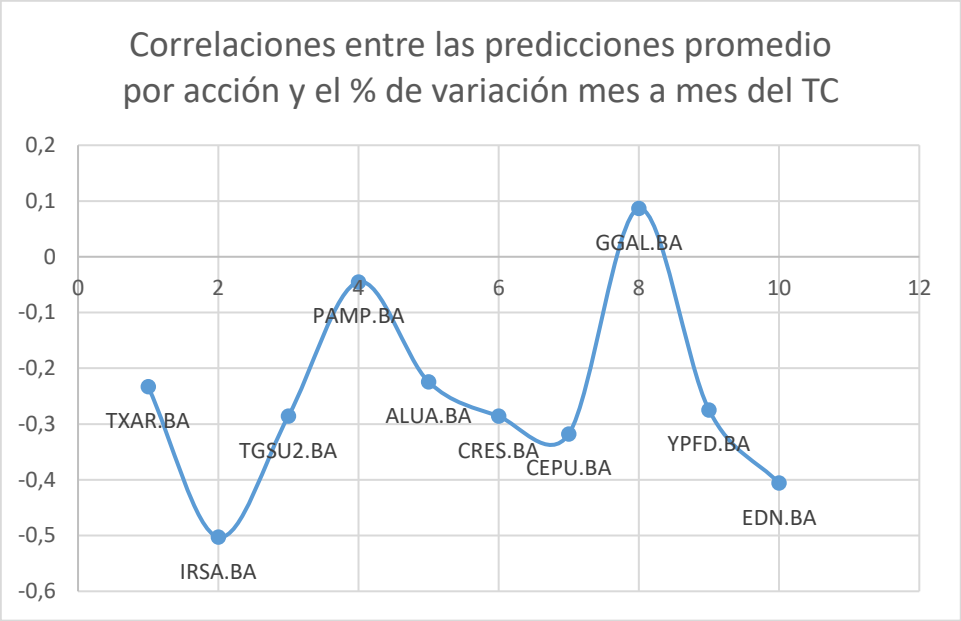

Gráfico 43 Correlaciones para cada acción con el porcentaje de variación del T.C.

Fuente: Elaboración Propia.

Al tomar acción por acción los resultados de las correlaciones obtenidas para todas las mismas variables analizadas previamente en el caso de los promedios mensuales son los siguiente:

	TXAR.BA	*IRSA.BA*	*TGSU2.BA*	*PAMP.BA*	*ALUA.BA*	*CRES.BA*	*CEPU.BA*	*GGAL.BA*	*YPFD.BA*	*EDN.BA*
CER	0,15294893	0,09302307	0,18821488	-0,0880466	-0,061279	-0,003979	0,59163757	-0,120529	0,21900565	0,10119492
Variacion % CER	-0,0210827	0,08444969	0,33651892	0,09317286	-0,1643635	-0,1475714	0,63783364	-0,3555701	0,16283938	0,0166407
TC	0,12536963	0,13459241	0,29538927	0,01133524	-0,1354363	-0,1251942	0,69350219	-0,2614238	0,26231024	0,01744746
Variacion % TC	-0,2330881	-0,502593	-0,2858287	-0,0452186	-0,2241941	-0,2861184	-0,3178468	0,08647803	-0,2746809	-0,4060915
Riesgo Pais	0,62120766	-0,4982379	-0,6025785	-0,726919	0,10363607	0,3146959	-0,1752904	0,43021843	0,19082659	0,00041334
Variacion % RP	-0,2259837	-0,2476528	-0,1287992	0,01247556	-0,0643836	-0,2069855	0,25641907	-0,5981515	0,13610668	-0,3683511
Base Monetaria	0,11283952	-0,1978293	0,17549071	-0,4919873	-0,0347342	0,36591542	0,80791999	-0,1423835	0,34060877	0,22782597
Variacion % B.M	-0,1692517	-0,5214797	0,2759287	-0,2182946	-0,2864284	0,15378033	0,44578086	-0,138261	-0,1189338	0,20699391
Tasa	-0,2974045	0,17147171	0,47633833	0,2831019	-0,2067427	-0,2402258	0,6020147	-0,5785629	0,1134428	-0,0681893
Variación % Tasa	-0,5523151	-0,0016238	-0,2561971	0,3246884	0,10223102	-0,0406021	-0,8840705	0,08020861	-0,5147506	-0,0926254
Depositos	0,16726172	0,08998781	0,21586375	-0,09931	-0,0764482	-0,0047181	0,61963397	-0,1314772	0,25148524	0,12605819
Variacion % Depositos	0,17294506	-0,3034072	0,43254533	-0,1634463	-0,4703978	-0,2472873	0,39332229	-0,2226394	0,19855412	0,07441999
CCL	-0,1392668	0,26353056	0,33373416	0,48222609	0,01146288	-0,1655074	0,30607367	-0,5413509	-0,0920624	-0,1290111
Variacion % CCL	0,24027379	0,30317344	-0,4953917	0,27056395	0,68307316	0,33993147	-0,7177549	-0,0392402	-0,2418098	-0,1591709

Tabla 30 Resumen de correlaciones halladas acción por acción

TXAR.BA

En el caso de la acción de Siderar, la principal correlación encontrada fue entre los porcentajes mensuales de aciertos y el Riesgo País, con un coeficiente de correlación de Pearson de 0,62120766

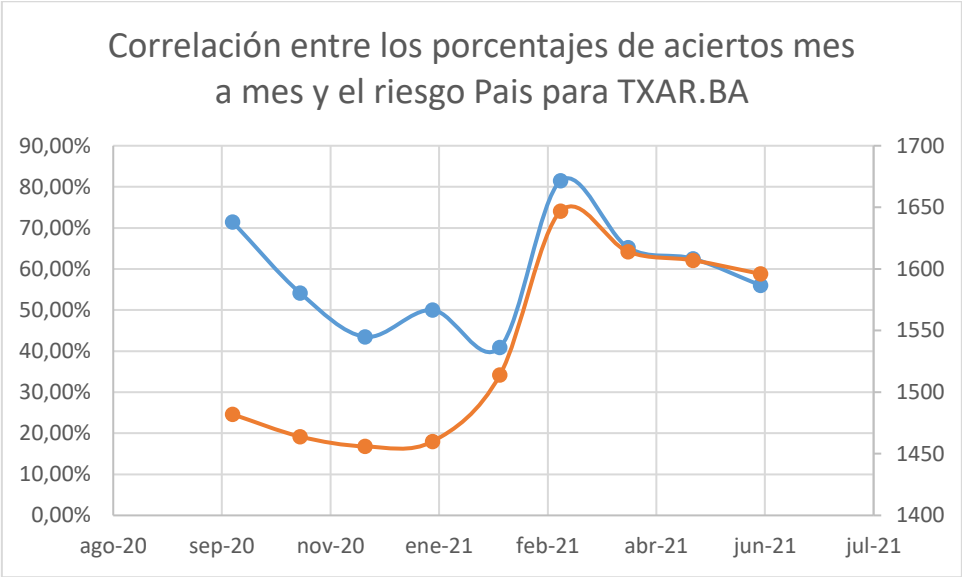

Gráfico 44 Correlación entre los porcentajes de aciertos mes a mes y el riego País para TXAR.BA.

Fuente: Elaboración Propia.

En segundo orden, encontramos una correlación inversa de -0,5523151 entre los aciertos mes a mes y el porcentaje de variación de la Tasa.

IRSA.BA

En el caso de IRSA, la principal correlación hallada es una correlación inversa con el porcentaje de variación mes a mes de la Base monetaria, con un coeficiente de correlación de -0,5214797.

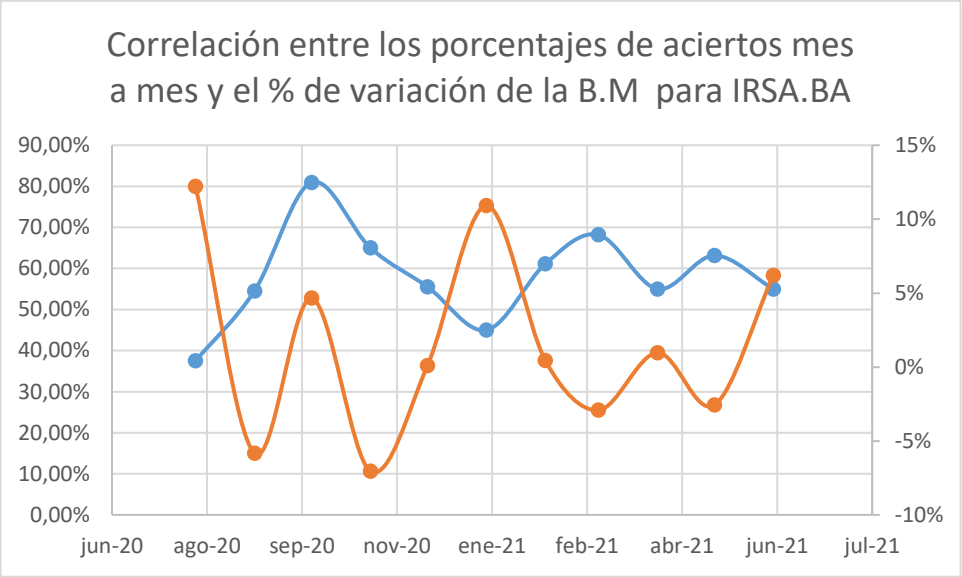

Gráfico 45 Correlación entre los porcentajes de aciertos mes a mes y el porcentaje de variación de la Base Monetaria para IRSA.BA.

Fuente: Elaboración Propia.

En segundo orden encontramos una correlación inversa con el riesgo país, teniendo un coeficiente de correlación de Pearson de -0,4982379.

TGSU2.BA

En el caso de Transportadora de Gas del Sur, la principal correlación encontrada es una correlación inversa con el Riesgo País, obteniendo un coeficiente de correlación de Pearson de -0,6025785.

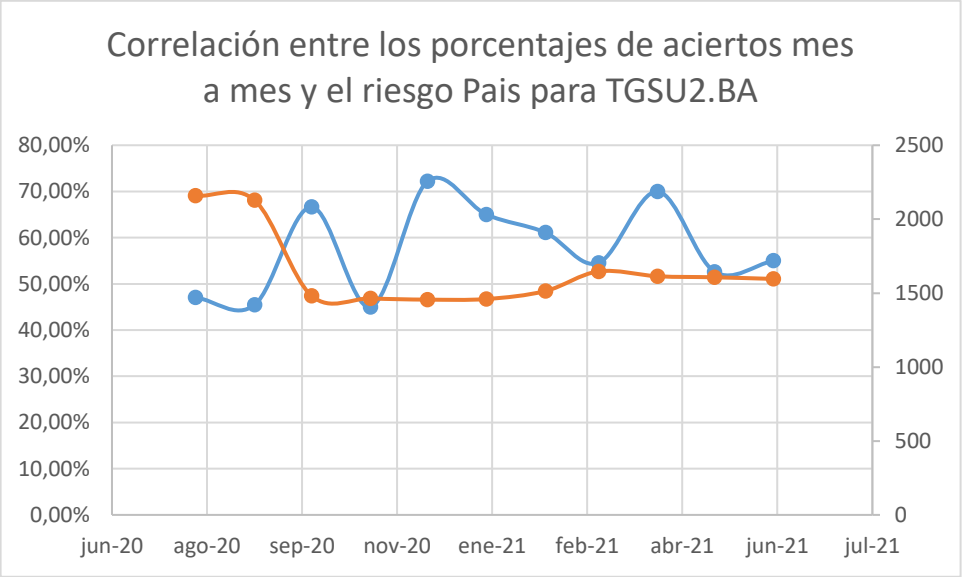

Gráfico 46 Correlación entre los porcentajes de aciertos mes a mes y el riesgo País para TGUS2.BA.

Fuente: Elaboración Propia.

En segundo orden hallamos una correlación inversa con la variación porcentual mes a mes del Contado con liquidación, alcanzando un coeficiente de Correlación de -0,4953917.

PAMP.BA

En el caso de PAMPA la mayor correlación hallada es una correlación inversa con la Base Monetaria, la misma arroja un coeficiente de correlación de -0,4919873.

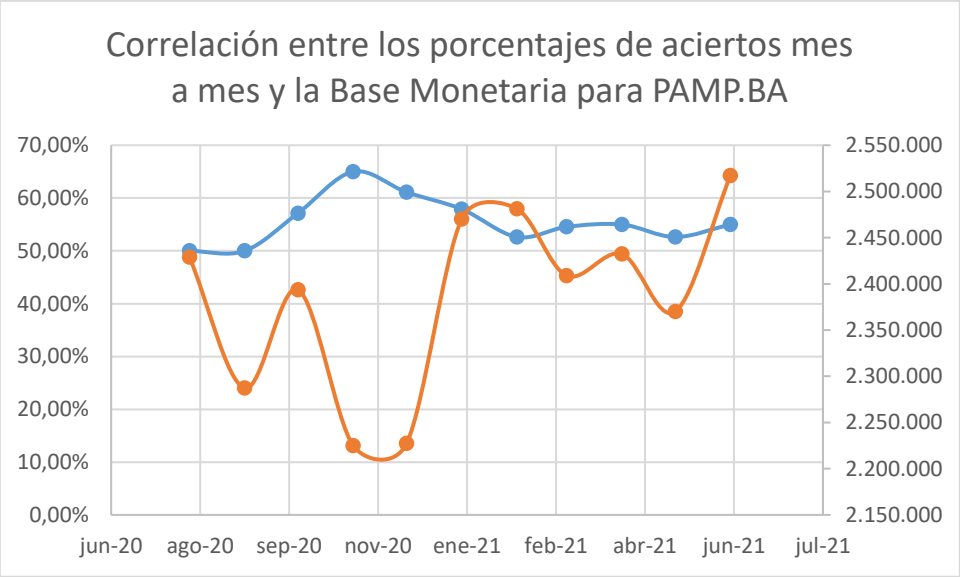

Gráfico 47 Correlación entre los porcentajes de aciertos mes a mes y la base monetaria para PAMP.BA.

Fuente: Elaboración Propia.

En segundo orden, pero con un valor absoluto muy similar, hallamos una correlación directa con el Contado con Liquidación, alcanzando un coeficiente de correlación de Pearson de 0,48222609.

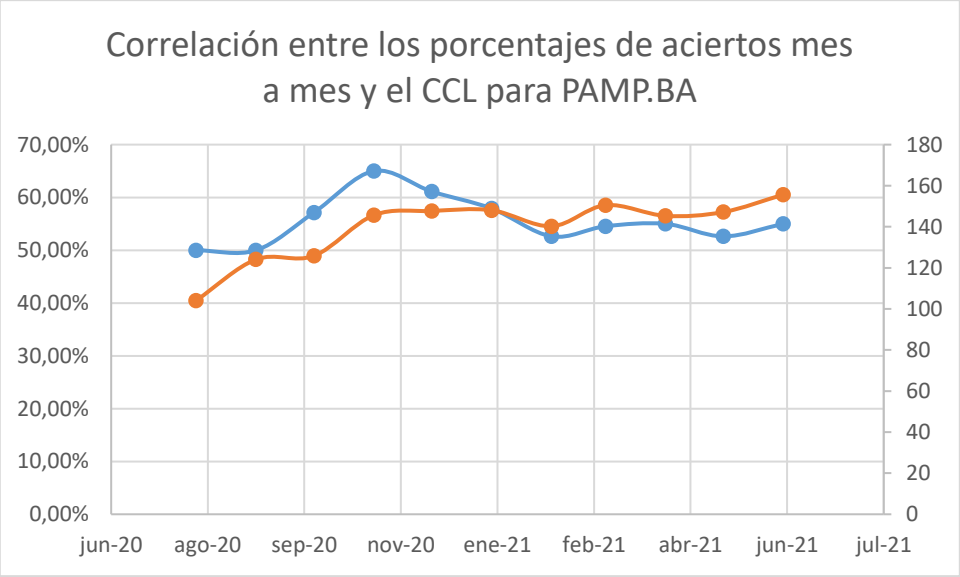

Gráfico 48 Correlación entre los porcentajes de aciertos mes a mes y el contado con liquidación para PAMP.BA.

Fuente: Elaboración Propia.

ALUA.BA

En el caso de Aluar, la mayor correlación hallada es una fuerte correlación directa con la variación mes a mes en porcentaje del Contado con Liquidación, arrojando un coeficiente de Correlación de Pearson de 0,68307316.

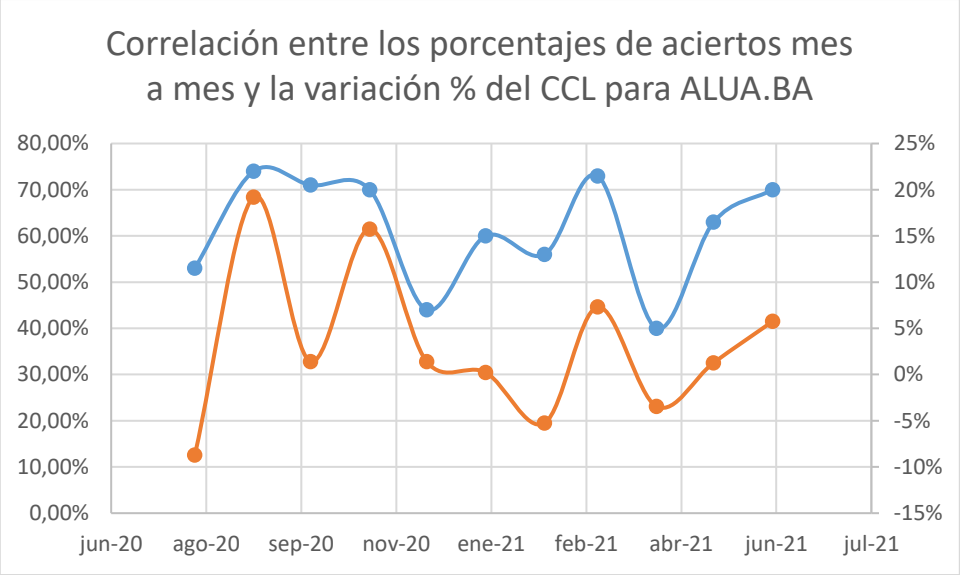

Gráfico 49 Correlación entre los porcentajes de aciertos mes a mes y la variación en porcentaje del Contado con Liquidación para ALUA.BA.

Fuente: Elaboración Propia.

En segundo orden hallamos una correlación inversa con la variación porcentual mes a mes del total de los depósitos con un coeficiente de correlación de -0,4703978.

CRES.BA

Para el caso de Cresud, la mejor correlación encontrada ha sido una correlación directa con la Base Monetaria, arrojando un coeficiente de correlación de Pearson de 0,36591542.

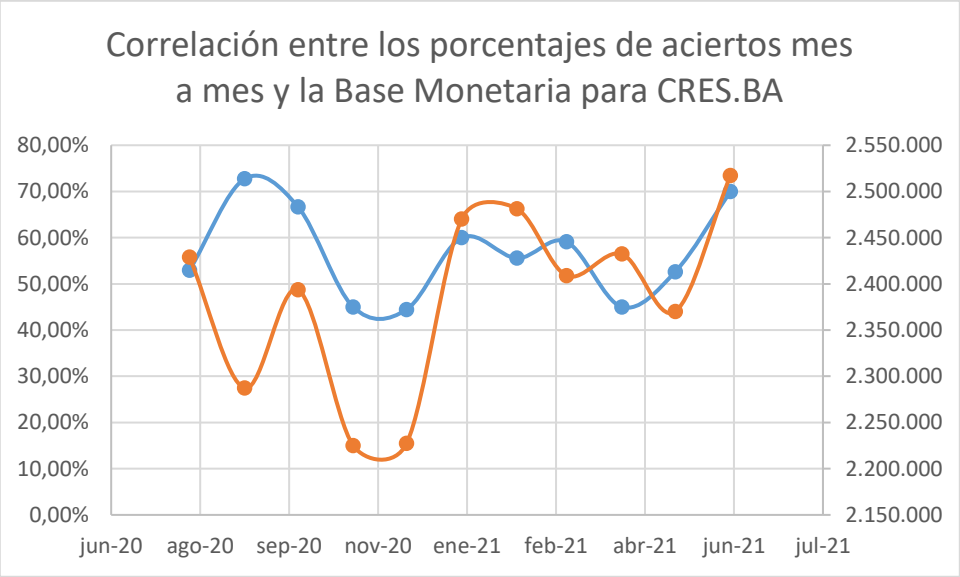

Gráfico 50 Correlación entre los porcentajes de aciertos mes a mes y la base monetaria para CRES.BA.

Fuente: Elaboración Propia.

En segundo orden hallamos una correlación directa con las variaciones en porcentaje mes a mes del Contado con Liquidación, teniendo un coeficiente de correlación de 0,33993147.

CEPU.BA

En el caso de Central Puerto, encontramos la mayor correlación de todas en una correlación inversa con la variación en porcentaje mes a mes de la tasa. En este caso el coeficiente de correlación de Pearson de -0,8840705.

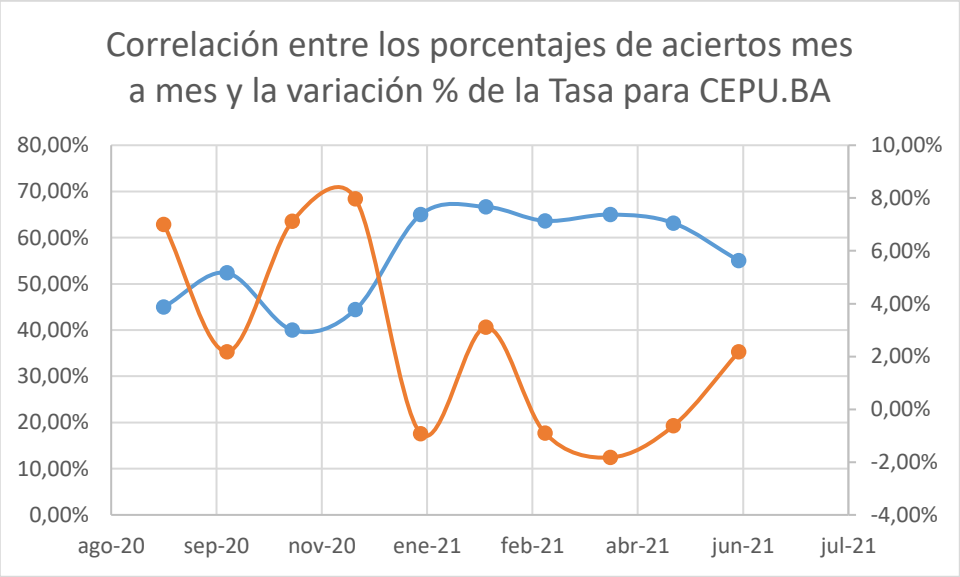

Gráfico 51 Correlación entre los porcentajes de aciertos mes a mes y la variación porcentual de la Tasa para CEPU.BA.

Fuente: Elaboración Propia.

En segundo orden encontramos una correlación directa con la base monetaria arrojando un coeficiente de correlación de Pearson de 0,80791999.

Como nota particular, esta acción es la que mejores correlaciones ha arrojado de todas las acciones analizadas. Presentando correlaciones importantes con casi todas las variables contrastadas.

	CEPU.BA
CER	0,59163757
Variacion % CER	0,63783364
TC	0,69350219
Variacion % TC	-0,3178468
Riesgo Pais	-0,1752904
Variacion % RP	0,25641907
Base Monetaria	0,80791999
Variacion % B.M	0,44578086
Tasa	0,6020147
Variación % Tasa	-0,8840705
Depositos	0,61963397
Variacion % Depositos	0,39332229
CCL	0,30607367
Variacion % CCL	-0,7177549

Tabla 31 Resumen de correlaciones halladas para CEPU.BA

GGAL.BA

En el caso del Banco Galicia, la mayor correlación encontrada es una correlación inversa la variación porcentual mes a mes del Riesgo País. Arrojando un coeficiente de correlación de Pearson de -0,5981515.

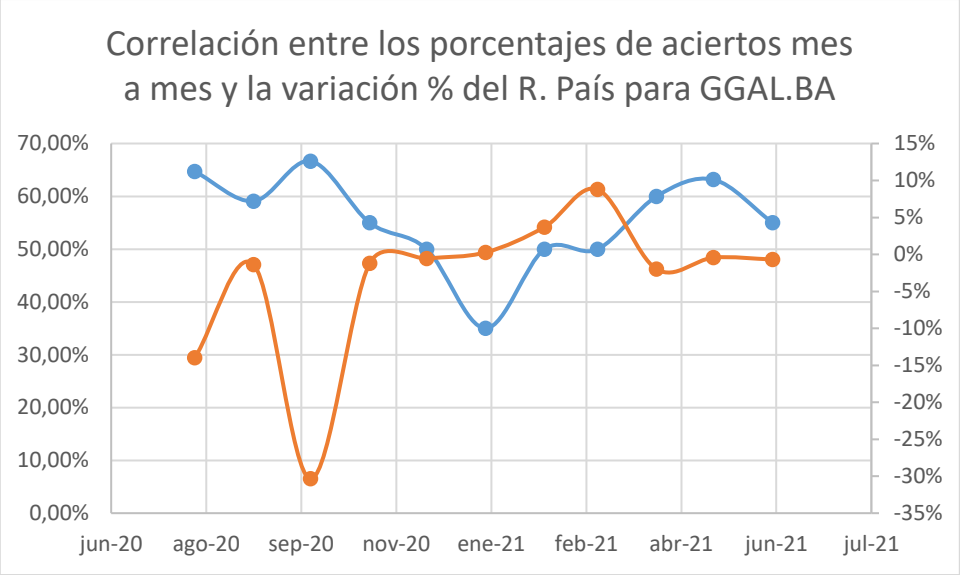

Gráfico 52 Correlación entre los porcentajes de aciertos mes a mes y la variación porcentual del Riesgo País para GGAL.BA.

Fuente: Elaboración Propia.

En segundo orden hallamos una correlación inversa con la Tasa, arrojando un coeficiente de correlación de Pearson de -0,5785629.

YPFD.BA

Para el caso de YPF, la principal correlación hallada es una correlación inversa con la variación porcentual mes a mes de la tasa. Arrojando un coeficiente de correlación de Pearson de -0,5147506.

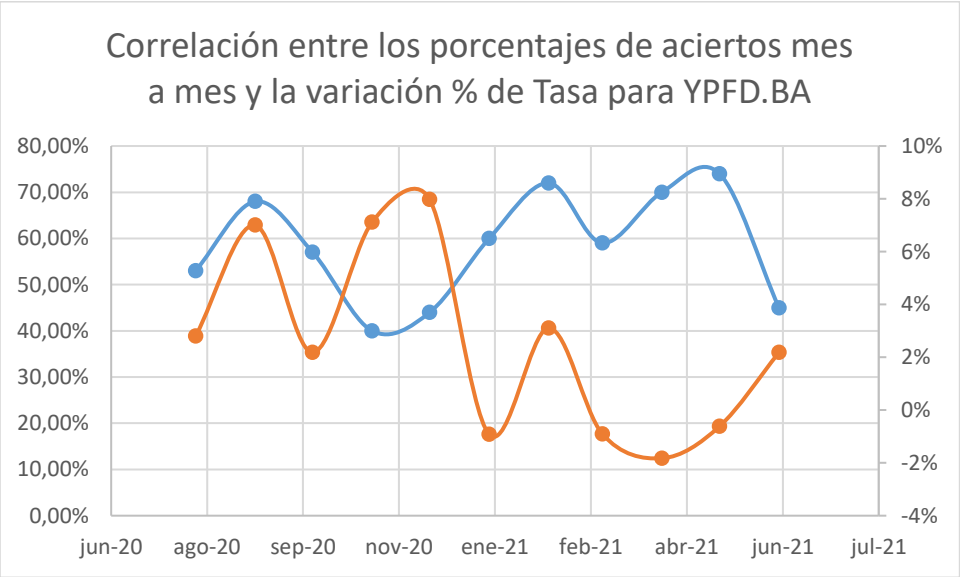

Gráfico 53 Correlación entre los porcentajes de aciertos mes a mes y la variación porcentual de la tasa para YPFD.BA.

Fuente: Elaboración Propia.

En segundo orden encontramos una correlación directa con la Base Monetaria, alcanzando un coeficiente de correlación de Pearson de 0,34060877.

EDN.BA

En el caso de Edenor la mejor correlación hallada es una correlación inversa con la variación porcentual mes a mes del Tipo de Cambio, arrojando un coeficiente de correlación de Pearson de -0,4060915.

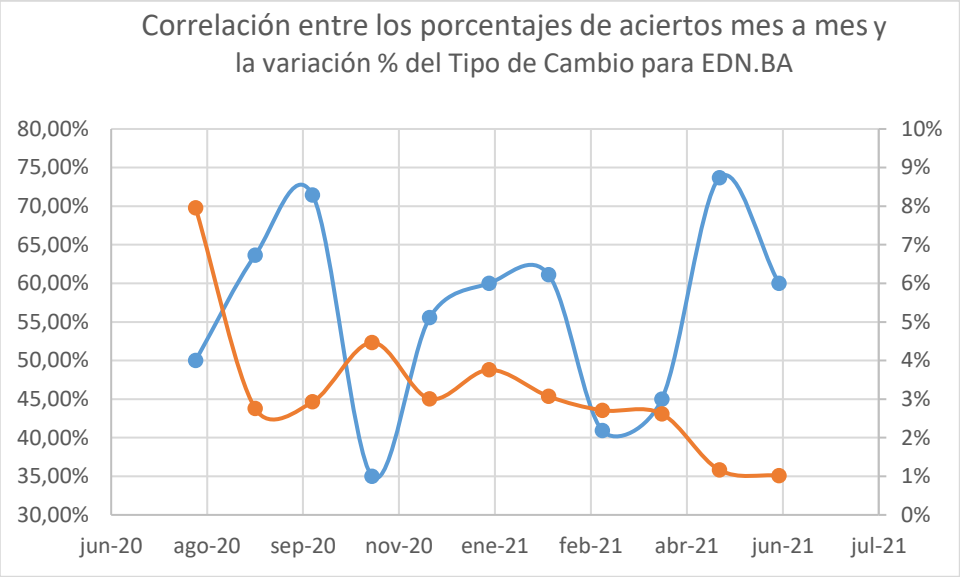

Gráfico 54 Correlación entre los porcentajes de aciertos mes a mes y la variación porcentual del Tipo de Cambio para EDN.BA.

Fuente: Elaboración Propia.

En segundo orden tenemos una correlación inversa con el porcentaje de variación mes a mes del Riesgo País, arrojando un coeficiente de correlación de -0,368351137.

7.14. Conclusiones.

En función de la información disponible utilizable como indicadores de la evolución de la macroeconomía y de las acciones para las cuales se obtuvieron las series de precios adecuadas, fueron seleccionadas todas las variables de trabajo.

Con muchas de ellas se procedió a crear diferentes combinaciones de redes neuronales, iterando para llegar al mejor resultado dentro de las posibilidades que otorgaba el poder computacional disponible.

El corte para definir el mejor modelo de trabajo se realizó con una red que utiliza una ventana de 35 precios y que tiene un conjunto adicional de entradas, sumadas a las series de precio de la acción, con las que se alcanzó un promedio de aciertos en las predicciones del **57,55%**.

Para la evaluación se consideró el intervalo de ventanas de precios entre 5 y 60 valores en función de los impactos evaluados en cuanto a costo computacional, habiendo

encontrado en primer lugar que el mismo comenzaba a dispararse de forma exponencial a partir de 100 precios y que adicionalmente no se hallaban evidencias de mejoras sustanciales en la capacidad de predicción para ese tamaño de ventana o mayor.

Con el modelo final seleccionado se procedió a verificar sus predicciones mes a mes y comparar estos grados de predicción alcanzados con las diferentes variables seleccionadas en representación de la macroeconomía.

Habiendo concluido la evaluación de la hipótesis, entendemos que efectivamente se ha podido encontrar correlaciones entre el movimiento de las variables macroeconómicas y la capacidad de predicción de las redes neuronales utilizadas.

Los resultados obtenidos de todos modos no nos permiten ser concluyentes ni son suficientes como para establecer una regla concreta.

Es importante de todos modos considerar el marco temporal en el cual se ha hecho este trabajo y la coyuntura de este.

Durante el período de evaluación la macroeconomía ha estado transitando una realidad relativamente inestable asociada no solo a las condiciones generadas por la pandemia del SARS COV2, sino también por las frágiles condiciones de la economía argentina debido entre otras cosas a su actual situación no resuelta en cuanto a deuda.

	Promedio Mes a Mes	***Dif promedio aciertos***
CER	0,265534771	-0,200942978
Variacion % CER	0,149533888	-0,269450787
TC	0,236347613	-0,229572951
Variacion % TC	**-0,592314586**	-0,262175958
Riesgo Pais	-0,128421687	**0,44025603**
Variacion % RP	-0,298317208	-0,231506823
Base Monetaria	0,301125291	0,187884311
Variacion % B.M	-0,135952531	0,208484401
Tasa	0,065616664	-0,291355264
Variación % Tasa	**-0,445501434**	-0,209294293
Depositos	0,286186891	-0,15573545
Variacion % Depositos	-0,025350371	0,325046291
CCL	0,070002299	**-0,542835286**
Variacion % CCL	0,081775567	-0,124369711

Tabla 32 Resumen de correlaciones halladas

Habida cuenta de que las principales correlaciones encontradas son correlaciones inversas (las tres principales) y considerando la evolución que han tenido estas variables.

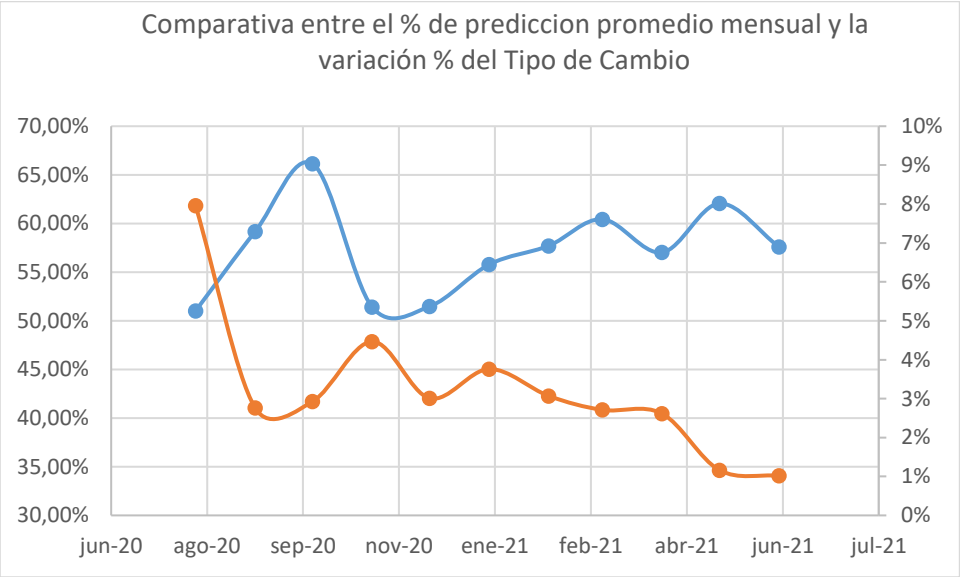

Gráfico 55 Comparativa entre el porcentaje de predicción promedio mensual y la variación porcentual del Tipo de Cambio.

Fuente: Elaboración Propia.

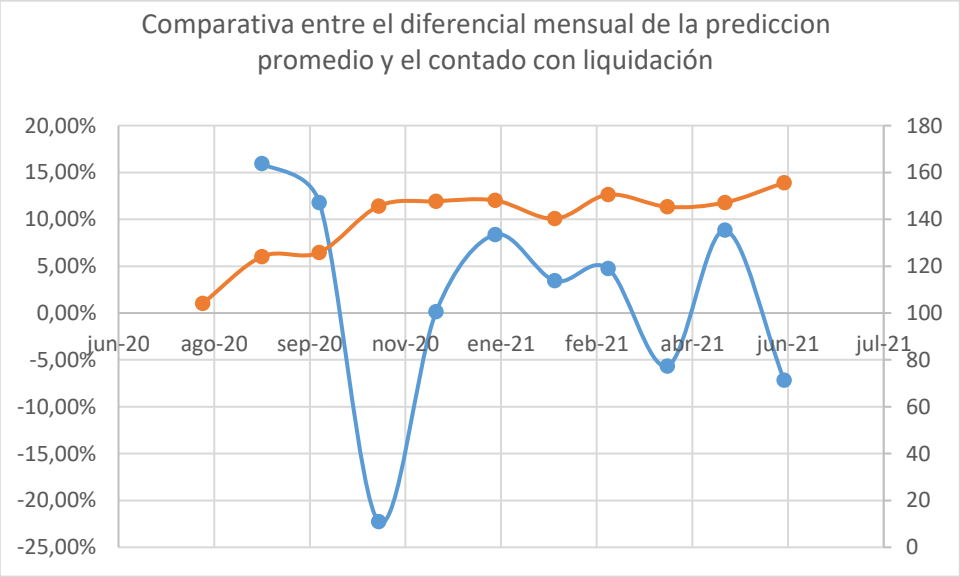

Gráfico 56 Comparativa entre el diferencial mensual de la predicción y el Contado con Liquidación.

Fuente: Elaboración Propia.

Es la opinión del autor que la principal conclusión que podemos sacar es que los movimientos de las variables macroeconómicas en dirección a condiciones inestables perjudican la capacidad de predicción de modelos que en definitiva basan sus predicciones

en la búsqueda de patrones repetidos en los movimientos de los precios y es esperable que condiciones erráticas generen movimientos más difíciles de predecir.

Este tipo de trabajos son dependientes de la posibilidad de acceder a volúmenes de datos suficientes como para ejecutar las evaluaciones realizadas, es posible establecer un próximo paso para otro trabajo testeando estas relaciones en un momento temporal de mayor estabilidad, o, también testeando estos modelos en economías más estables.

Debe considerarse también el hecho de que las diferentes acciones evaluadas no han generado las mismas correlaciones. No podemos sacar conclusiones sobre las razones por las cuales las diferentes acciones correlacionan de diferente manera con las variables, aunque, entendemos que podría deberse esto al hecho de que las diferentes compañías analizadas están enfocadas en diferentes rubros y podrían estos reaccionar de distinto modo a las condiciones de mercado.

Por ejemplo, no sería lo mismo que una compañía este claramente enfocada a mercado interno o su actividad sea meramente exportadora.

8. Anexo

8.1. El código fuente

A medida que el trabajo fue avanzando, el código fuente en Python fue cambiando para adaptarse a las diferentes pruebas realizadas. La versión final del código fuente que vamos a documentar corresponde al código que permite entrenar una red basada en múltiples entradas tomando los datos a partir de archivos de texto separado por comas.

Como en todas las pruebas se analizan las 10 acciones seleccionadas (TXAR.BA, IRSA.BA, TGSU2.BA, PAMP.BA, ALUA.BA, CRES.BA, CEPU.BA, GGAL.BA, YPFD.BA y EDN.BA), todo el código fuente que será descrito se encuentra encerrado en un loop que lo repite por cada una de estas acciones.

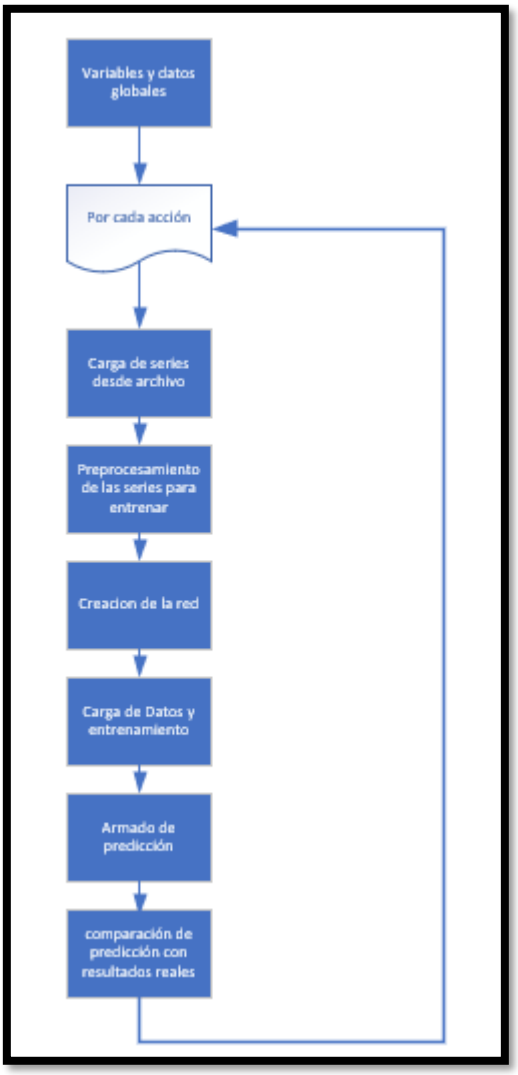

Gráfico 57 Diagrama de flujo del código

8.1.1. Variables y datos globales.

```
# -*- coding: utf-8 -*-
"""
Created on Sun May 16 21:02:32 2021

@author: Gustavo Palomero
"""

import yfinance as yf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import datetime

#Tickers de acciones que se evaluan
acciones=['EDN.BA','YPFD.BA','GGAL.BA','CEPU.BA','CRES.BA','ALUA.BA','PAMP.BA','TXAR.BA','TGSU2.BA','IRSA.BA']
#Modelo aplicado para cada accion
caso_x_accion=[7,9,4,10,11,10,4,8,4,4]
lbs=[35] #Tamaño de la ventana
epochs_v=[500] #Cantidad de Epochs o pasadas para cada entrenamiento

#Paquete de variables globales utilizadas para evaluaciones
mejor_resultado_promedio=0
mejor_lb=0
mejor_media1=0
mejor_media2=0
mejor_ep=0
mejor_caso=1

Resultados_pos=[]
Resultados_neg=[]
mejor_resultado_promedio=0
#Fin Paquete de variables globales utilizadas para evaluaciones

muestra_graficos=False #Si vale True al terminar cada accion arma los graficos resultantes
grabar_modelo=False #Si vale True al terminar todas las acciones graba el modelo Tensorflow resultaten
aplicar_casos_particulares=True #Si vale True aplica los diferentes modelos definidos en el vector casos_x_accion
```

Gráfico 58 Extracto de código fuente para definiciones globales e inicializaciones

Las diferentes acciones evaluadas se encuentran codificadas a través de su Ticker dentro de un vector unidimensional.

También codificamos en un vector unidimensional el número de modelo a aplicar con cada acción en particular.

Se establecen además una serie de variables globales que serán utilizadas como Flags Para controlar el comportamiento del programa en las sucesivas corridas.

8.1.2. Carga de Series desde archivos.

```
data=pd.read_csv(accion+'.csv',sep=';')
spdata=pd.read_csv('indiceSp.csv',sep=';')

merv_data=pd.read_csv('Merval.csv',sep=';')
dol_data=pd.read_csv('dolar.csv',sep=';')
brentdata=pd.read_csv('pet_brent.csv',sep=';')
sojadata=pd.read_csv('cotsoja.csv',sep=';')
```

Gráfico 59 Extracto de código fuente para carga de series desde archivos

La información para alimentar las variables que contienen las series debe estar en el mismo directorio de trabajo del código fuente con la información en texto separado por puntos y coma.

8.1.3. Preprocesamiento de las Series para entrenar.

Esta sección contempla por un lado el fraccionamiento de las series en dos partes, la sección de entrenamiento correspondiente al 90% del total de elementos y la sección para verificar las predicciones hechas correspondiente al 10% restante.

Otro preprocesamiento necesario es el armado de las medias móviles que serán utilizadas.

Es importante recordar que las redes neuronales trabajan con conjuntos de valores escalados entre 0 y 1 por lo cual en esta sección se procede también a dicho escalamiento.

```
# Escalamiento
from sklearn import preprocessing

cl = data.Close.astype('float32')
train = cl[0:int(len(cl)*0.80)]
scl = preprocessing.MinMaxScaler()

scl.fit(train.values.reshape(-1,1))
cl =scl.transform(cl.values.reshape(-1,1))

scl2=preprocessing.MinMaxScaler()
cl_volumen=data.Volume.astype('float32')
train_volume=cl_volumen[0:int(len(cl_volumen)*0.80)]
scl2.fit(train_volume.values.reshape(-1,1))
cl_volumen =scl2.transform(cl_volumen.values.reshape(-1,1))
```

Gráfico 60 Extracto de código fuente para escalamientos

En el caso de las series que serán procesadas en capas Densas, las mismas serán convertidas a vectores de tipo float32 con la librería numpy, a través de las siguientes funciones.

```
def Preprocesa_mervdata(merval):
    columna=merval.columns.get_loc('Valor')
    salida=np.arange(len(merval),dtype=float)
    for i in range(0,len(merval)):
        salida[i]=(float(merval.iloc[i,columna]))
    return salida

def Preprocesa_spdata(sp500data):
    columna=sp500data.columns.get_loc('Valor')
    salida=np.arange(len(sp500data),dtype=float)
    for i in range(0,len(sp500data)):
        salida[i]=(float(sp500data.iloc[i,columna]))
    return salida


def Preprocesa_doldata(dol):
    columna=dol.columns.get_loc('Valor')
    salida=np.arange(len(dol),dtype=float)
    for i in range(0,len(dol)):
        salida[i]=(float(dol.iloc[i,columna]))
    return salida

def Preprocesa_brentdata(brent):
    columna=brent.columns.get_loc('Valor')
    salida=np.arange(len(brent),dtype=float)
    for i in range(0,len(brent)):
        salida[i]=(float(brent.iloc[i,columna]))
    return salida

def Preprocesa_sojadata(soja):
    columna=soja.columns.get_loc('Valor')
    salida=np.arange(len(soja),dtype=float)
    for i in range(0,len(soja)):
        salida[i]=(float(soja.iloc[i,columna]))
    return salida
```

```
def processData(data,lb):
    X,Y = [],[]
    for i in range(len(data)-lb-1):
        X.append(data[i:(i+lb),0])
        Y.append(data[(i+lb),0])
    return np.array(X),np.array(Y)

def prepro_volumen(data,lb):
    vl=[]
    for i in range(lb,len(data)-1):
        vl.append(data[i])
    return np.array(vl)

def prepro_volumen(data,lb):
    vl=[]
    for i in range(lb,len(data)-1):
        vl.append(data[i])
    return np.array(vl)
```

Gráfico 61 Extracto de código fuente para preprocesamiento

La función processData genera las tuplas de entrada para las series de precios descriptas en “Tratamiento de la entrada de la serie de precios para entrenar una red LSTM.”

```
def media_movil(lista_de_datos,tam_ventana):
    import numpy as np
    media_inmediata=0
    media=np.arange(len(lista_de_datos),dtype=float)

    suma=0
    #print("Largo",len(media),len(lista_de_datos))
    for i in range(0,len(lista_de_datos)):

        if(i==tam_ventana-1):
            for j in range(i-tam_ventana,tam_ventana-1):
                suma+=lista_de_datos[j]
            media_inmediata=suma/tam_ventana
            for j in range(i-tam_ventana,tam_ventana-1):
                #np.append(media,media_inmediata)
                print(j)
                media[j+1]=media_inmediata

        else:

            if(i>tam_ventana-1):
                suma=0
                for j in range(i-tam_ventana,i):
                    suma+=lista_de_datos[j]
                media_inmediata=suma/tam_ventana
                #np.append(media,media_inmediata)
                media[i]=media_inmediata
    return media
```

```
relacion_training=0.9
media1=5
media2=15
X,y = processData(cl,lb)
volumen=prepro_volumen(cl_volumen,lb)
merv_data2=Preprocesa_mervdata(merv_data)
spdata2=Preprocesa_spdata(spdata)
brent_data2=Preprocesa_brentdata(brentdata)
sojadata=Preprocesa_sojadata(sojadata)
scl3=preprocessing.MinMaxScaler()
scl3.fit(merv_data2.reshape(-1,1))
merv_data2 =scl3.transform(merv_data2.reshape(-1,1))
dol_data2=Preprocesa_doldata(dol_data)
scl4=preprocessing.MinMaxScaler()
scl4.fit(dol_data2.reshape(-1,1))
dol_data2 =scl4.transform(dol_data2.reshape(-1,1))
sclsp = preprocessing.MinMaxScaler()
sclsp.fit(spdata2.reshape(-1,1))
spdata2 =scl4.transform(spdata2.reshape(-1,1))
sclbrent = preprocessing.MinMaxScaler()
sclbrent.fit(brent_data2.reshape(-1,1))
brent_data2 =sclbrent.transform(brent_data2.reshape(-1,1))
sclsoja = preprocessing.MinMaxScaler()
sclsoja.fit(sojadata.reshape(-1,1))
sojadata2 =sclsoja.transform(sojadata.reshape(-1,1))
mmv=media_movil(y,media1)
mmv2=media_movil(y,media2)
X_train,X_test = X[:int(X.shape[0]*relacion_training)],X[int(X.shape[0]*relacion_training):]
y_train,y_test = y[:int(y.shape[0]*relacion_training)],y[int(y.shape[0]*relacion_training):]
```

```
vol_train,vol_test=volumen[:int(volumen.shape[0]*relacion_training)],volumen[int(volumen.shape[0]*relacion_training):]
mmv_test=mmv[int(len(mmv)*relacion_training):]
mmv_test2=mmv2[int(len(mmv2)*relacion_training):]
mmv_train=mmv[:int(len(mmv)*relacion_training)]
mmv_train2=mmv2[:int(len(mmv2)*relacion_training)]
origen=len(merv_data2)-len(mmv)
merval_train,merval_test=merv_data2[origen-1:int(X.shape[0]*relacion_training)+origen-1],merv_data2[int(X.shape[0]*relacion_training)+origen:]

dolar_train,dolar_test=dol_data2[origen-1:int(X.shape[0]*relacion_training)+origen-1],dol_data2[int(X.shape[0]*relacion_training)+origen:]

sp_train,sp_test=spdata2[origen-1:int(X.shape[0]*relacion_training)+origen-1],spdata2[int(X.shape[0]*relacion_training)+origen:]

brent_train,brent_test=brent_data2[origen-1:int(X.shape[0]*relacion_training)+origen-1],brent_data2[int(X.shape[0]*relacion_training)+origen:]

soja_train,soja_test=sojadata2[origen-1:int(X.shape[0]*relacion_training)+origen-1],sojadata2[int(X.shape[0]*relacion_training)+origen:]

fechas=Obtiene_Fechas(data,int(X.shape[0]*relacion_training)+lb+1)
```

8.1.4. Creación de la Red

```
from tensorflow.keras import Sequential

from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, Dropout, LSTM, Input, Activation, concatenate
from tensorflow.keras import optimizers

history_points = 50
```

```
#Para poder injestar en Tensorflow es necesario cambiar las dimensiones de los vectores
X_train = X_train.reshape((X_train.shape[0],X_train.shape[1],1))
X_test = X_test.reshape((X_test.shape[0],X_test.shape[1],1))

mmv_train=mmv_train.reshape((mmv_train.shape[0],1))


mmv_test=mmv_test.reshape((mmv_test.shape[0],1))

vol_train=vol_train.reshape((vol_train.shape[0],1))

vol_test=vol_test.reshape((vol_test.shape[0],1))

merval_test=merval_test.reshape((merval_test.shape[0],1))
merval_train=merval_train.reshape((merval_train.shape[0],1))

dolar_test=dolar_test.reshape((dolar_test.shape[0],1))
dolar_train=dolar_train.reshape((dolar_train.shape[0],1))

sp_test=sp_test.reshape((sp_test.shape[0],1))
sp_train=sp_train.reshape((sp_train.shape[0],1))


brent_test=brent_test.reshape((brent_test.shape[0],1))
brent_train=brent_train.reshape((brent_train.shape[0],1))

soja_test=soja_test.reshape((soja_test.shape[0],1))
soja_train=soja_train.reshape((soja_train.shape[0],1))
```

Gráfico 62 Extracto de código fuente para la creación de la red

```
#inputs de todas la capas

lstm_input = Input(shape=(lb, 1), name='lstm_input')

dense_input = Input(shape=(1,), name='tech_input')

dense_input2 = Input(shape=(1,), name='tech_input2')


dense_input_vol=Input(shape=(1,),name='vol_input')

dense_input_mv=Input(shape=(1,),name='mv_input')

dense_input_dl=Input(shape=(1,),name='dl_input')

dense_input_sp=Input(shape=(1,),name='sp_input')

dense_input_br=Input(shape=(1,),name='br_input')


dense_input_so=Input(shape=(1,),name='so_input')
```

```
x = LSTM(250, name='lstm_0')(lstm_input)
lstm_branch = Model(inputs=lstm_input, outputs=x)
lstm_branch.summary()
if ((caso>=3 and caso<=6) or caso==7 or caso==8 or caso==9 or caso==10 or caso==11):
    y = Dense(300, name='tech_dense_0')(dense_input)
    y = Activation("relu", name='tech_relu_0')(y)
    y = Dropout(0.2, name='tech_dropout_0')(y)
    technical_indicators_branch = Model(inputs=dense_input, outputs=y)

    y2 = Dense(300, name='tech_dense_2')(dense_input2)
    y2 = Activation("relu", name='tech_relu_2')(y2)
    y2 = Dropout(0.2, name='tech_dropout_2')(y2)
    technical_indicators_branch2 = Model(inputs=dense_input2, outputs=y2)
    technical_indicators_branch2.summary()

#tercera entrada Volumen
if (caso!=6 and caso!=8):
    vm=Dense(300,name='vol_dense_0')(dense_input_vol)
    vm=Activation("relu",name='vol_relu_0')(vm)
    vm=Dropout(0.2,name='vol_dropout_0')(vm)
    volume_branch=Model(inputs=dense_input_vol,outputs=vm)
```

```
#cuarta entrada merval
if (caso==10 or caso==11 or caso==8 or caso==9 or caso==7 or (caso>=4 and caso<=6)):
    mv=Dense(300,name='mv_dense_0')(dense_input_mv)
    mv=Activation("relu",name='mv_relu_0')(mv)
    mv=Dropout(0.2,name='mv_dropout_0')(mv)
    merval_branch=Model(inputs=dense_input_mv,outputs=mv)

#cuarta entrada dolar
if (caso==10 or caso==11 or caso==8 or caso==9 or caso==7 or(caso<=4 or caso==6)):
    dl=Dense(300,name='dl_dense_0')(dense_input_dl)
    dl=Activation("relu",name='dl_relu_0')(dl)
    dl=Dropout(0.2,name='dl_dropout_0')(dl)
    dolar_branch=Model(inputs=dense_input_dl,outputs=dl)


#QUINTA SP500
if (caso!=11 and caso!=10 and (caso==9 or (caso>1 and caso<=6))):
    spd=Dense(300,name='sp_dense_0')(dense_input_sp)
    spd=Activation("relu",name='sp_relu_0')(spd)
    spd=Dropout(0.2,name='sp_dropout_0')(spd)
    sp_branch=Model(inputs=dense_input_sp,outputs=spd)


if(caso==9 or caso ==10):
    brd=Dense(300,name='br_dense_0')(dense_input_br)
    brd=Activation("relu",name='br_relu_0')(brd)
    brd=Dropout(0.2,name='br_dropout_0')(brd)
    brent_branch=Model(inputs=dense_input_br,outputs=brd)

if(caso==11):
    soj=Dense(300,name='sj_dense_0')(dense_input_so)
    soj=Activation("relu",name='sj_relu_0')(soj)
    soj=Dropout(0.2,name='sj_dropout_0')(soj)
    soja_branch=Model(inputs=dense_input_so,outputs=soj)
```

```
    # combinación de capas segun cada caso
    if(caso==1):
        combined = concatenate([lstm_branch.output, volume_branch.output,dolar_branch.output], name='concatenate')
    if(caso==2):
        combined = concatenate([lstm_branch.output, volume_branch.output,dolar_branch.output,sp_branch.output], name='concatenate')
    if(caso==3):
        combined = concatenate([lstm_branch.output, technical_indicators_branch.output,technical_indicators_branch2.output,
                                volume_branch.output,dolar_branch.output,sp_branch.output], name='concatenate')
    if(caso==4):
        combined = concatenate([lstm_branch.output, technical_indicators_branch.output,technical_indicators_branch2.output,
                                volume_branch.output,merval_branch.output,dolar_branch.output,sp_branch.output], name='concatenate')
    if(caso==5):
        combined = concatenate([lstm_branch.output, technical_indicators_branch.output,technical_indicators_branch2.output,
                                volume_branch.output,merval_branch.output,sp_branch.output], name='concatenate')
    if(caso==6):
        combined = concatenate([lstm_branch.output, technical_indicators_branch.output,technical_indicators_branch2.output,merval_branch.output,
                                sp_branch.output], name='concatenate')
    if(caso==7):
        combined = concatenate([lstm_branch.output, technical_indicators_branch.output,technical_indicators_branch2.output,
                                volume_branch.output,merval_branch.output,dolar_branch.output], name='concatenate')
    if(caso==8):
        combined = concatenate([lstm_branch.output, technical_indicators_branch.output,technical_indicators_branch2.output,
                                merval_branch.output,dolar_branch.output], name='concatenate')
    if(caso==9):
        combined = concatenate([lstm_branch.output, technical_indicators_branch.output,technical_indicators_branch2.output,
                                volume_branch.output,merval_branch.output,dolar_branch.output,sp_branch.output,brent_branch.output], name='concatenate')
    if(caso==10):
        combined = concatenate([lstm_branch.output, technical_indicators_branch.output,technical_indicators_branch2.output,
                                volume_branch.output,merval_branch.output,dolar_branch.output,brent_branch.output], name='concatenate')
    if(caso==11):
        combined = concatenate([lstm_branch.output, technical_indicators_branch.output,technical_indicators_branch2.output,
                                volume_branch.output,merval_branch.output,dolar_branch.output,soja_branch.output], name='concatenate')

    z = Dense(2048, activation="sigmoid", name='dense_pooling')(combined)
    z = Dense(1, activation="linear", name='dense_out')(z)
```

```
if (caso==1):
    model = Model(inputs=[lstm_branch.input, volume_branch.input,dolar_branch.input], outputs=z,name=accion)
if (caso==2):
    model = Model(inputs=[lstm_branch.input, volume_branch.input,dolar_branch.input,sp_branch.input], outputs=z,name=accion)
if (caso==3):
    model = Model(inputs=[lstm_branch.input, technical_indicators_branch.input,technical_indicators_branch2.input,
                          volume_branch.input,dolar_branch.input,sp_branch.input], outputs=z,name=accion)
if (caso==4):
    model = Model(inputs=[lstm_branch.input, technical_indicators_branch.input,technical_indicators_branch2.input,
                          volume_branch.input,merval_branch.input,dolar_branch.input,sp_branch.input], outputs=z,name=accion)
if (caso==5):
    model = Model(inputs=[lstm_branch.input, technical_indicators_branch.input,technical_indicators_branch2.input,
                          volume_branch.input,merval_branch.input,sp_branch.input], outputs=z,name=accion)
if (caso==6):
    model = Model(inputs=[lstm_branch.input, technical_indicators_branch.input,technical_indicators_branch2.input,
                          merval_branch.input,dolar_branch.input,sp_branch.input], outputs=z,name=accion)
if (caso==7):
    model = Model(inputs=[lstm_branch.input, technical_indicators_branch.input,technical_indicators_branch2.input,
                          volume_branch.input,merval_branch.input,dolar_branch.input], outputs=z,name=accion)
if (caso==8):
    model = Model(inputs=[lstm_branch.input, technical_indicators_branch.input,technical_indicators_branch2.input,
                          merval_branch.input,dolar_branch.input], outputs=z,name=accion)
if (caso==9):
    model = Model(inputs=[lstm_branch.input, technical_indicators_branch.input,technical_indicators_branch2.input,
                          volume_branch.input,merval_branch.input,dolar_branch.input,sp_branch.input,brent_branch.input], outputs=z,name=accion)
if (caso==10):
    model = Model(inputs=[lstm_branch.input, technical_indicators_branch.input,technical_indicators_branch2.input,
                          volume_branch.input,merval_branch.input,dolar_branch.input,brent_branch.input], outputs=z,name=accion)
if (caso==11):
    model = Model(inputs=[lstm_branch.input, technical_indicators_branch.input,technical_indicators_branch2.input,
                          volume_branch.input,merval_branch.input,dolar_branch.input,soja_branch.input], outputs=z,name=accion)

adam = optimizers.Adam(lr=0.0005)

model.compile(optimizer=adam,loss='mse')
```

```
if (caso==1):
        model.fit(x=[X_train,vol_train,dolar_train], y=y_train, batch_size=32, epochs=epochs, shuffle=True, validation_split=0.1)
if (caso==2):
        model.fit(x=[X_train,vol_train,dolar_train,sp_train], y=y_train, batch_size=32, epochs=epochs, shuffle=True, validation_split=0.1)
if (caso==3):
        model.fit(x=[X_train,mmv_train,mmv_train2,vol_train,dolar_train,sp_train], y=y_train, batch_size=32,
                epochs=epochs, shuffle=True, validation_split=0.1)
if (caso==4):
        model.fit(x=[X_train,mmv_train,mmv_train2,vol_train,merval_train,dolar_train,sp_train], y=y_train,
                batch_size=32, epochs=epochs, shuffle=True, validation_split=0.1)
if (caso==5):
        model.fit(x=[X_train,mmv_train,mmv_train2,vol_train,merval_train,sp_train], y=y_train, batch_size=32,
                epochs=epochs, shuffle=True, validation_split=0.1)
if (caso==6):
        model.fit(x=[X_train,mmv_train,mmv_train2,merval_train,dolar_train,sp_train], y=y_train, batch_size=32,
                epochs=epochs, shuffle=True, validation_split=0.1)
if (caso==7):
        model.fit(x=[X_train,mmv_train,mmv_train2,vol_train,merval_train,dolar_train], y=y_train, batch_size=32,
                epochs=epochs, shuffle=True, validation_split=0.1)
if (caso==8):
        model.fit(x=[X_train,mmv_train,mmv_train2,merval_train,dolar_train], y=y_train, batch_size=32, epochs=epochs,
                shuffle=True, validation_split=0.1)
if (caso==9):
        model.fit(x=[X_train,mmv_train,mmv_train2,vol_train,merval_train,dolar_train,sp_train,brent_train], y=y_train,
                batch_size=32, epochs=epochs, shuffle=True, validation_split=0.1)
if (caso==10):
        model.fit(x=[X_train,mmv_train,mmv_train2,vol_train,merval_train,dolar_train,brent_train], y=y_train,
                batch_size=32, epochs=epochs, shuffle=True, validation_split=0.1)
if (caso==11):
        model.fit(x=[X_train,mmv_train,mmv_train2,vol_train,merval_train,dolar_train,soja_train], y=y_train,
                batch_size=32, epochs=epochs, shuffle=True, validation_split=0.1)
```

8.1.5. Armado de predicción.

```
if (caso==1):
    Xt = model.predict([X_test,vol_test,dolar_test])
if (caso==2):
    Xt = model.predict([X_test,vol_test,dolar_test,sp_test])
if (caso==3):
    Xt = model.predict([X_test,mmv_test,mmv_test2,vol_test,dolar_test,sp_test])
if (caso==4):
    Xt = model.predict([X_test,mmv_test,mmv_test2,vol_test,merval_test,dolar_test,sp_test])
if (caso==5):
    Xt = model.predict([X_test,mmv_test,mmv_test2,vol_test,merval_test,sp_test])
if (caso==6):
    Xt = model.predict([X_test,mmv_test,mmv_test2,merval_test,dolar_test,sp_test])
if (caso==7):
    Xt = model.predict([X_test,mmv_test,mmv_test2,vol_test,merval_test,dolar_test])
if (caso==8):
    Xt = model.predict([X_test,mmv_test,mmv_test2,merval_test,dolar_test])
if (caso==9):
    Xt = model.predict([X_test,mmv_test,mmv_test2,vol_test,merval_test,dolar_test,sp_test,brent_test])
if (caso==10):
    Xt = model.predict([X_test,mmv_test,mmv_test2,vol_test,merval_test,dolar_test,brent_test])
if (caso==11):
    Xt = model.predict([X_test,mmv_test,mmv_test2,vol_test,merval_test,dolar_test,soja_test])
```

Gráfico 63 Extracto de código fuente para la predicción

8.1.6. Comparación de predicción con resultados reales.

```
resultadopos=0
resultadoneg=0

for i in range(0,len(y_test)):
    if y_test[i]>=y_test[i-1] and Xt[i]>= Xt[i-1]:
        resultadopos=resultadopos+1
    else:
        if y_test[i]<y_test[i-1] and Xt[i]< Xt[i-1]:
            resultadopos=resultadopos+1
        else:
            resultadoneg=resultadoneg+1

    aciertos_acumulados.append(resultadopos)
    errores_acumulados.append(resultadoneg)



print("Porcentaje positivos:",resultadopos/len(y_test)*100,"%")
print("Porcentaje Negativos:",resultadoneg/len(y_test)*100,"%")
```

Gráfico 64 Extracto de código fuente para la evaluación de los resultados

9. Bibliografía.

Alcalá Nalvaiz, T. (2018). *Introducción a los modelos de redes neuronales artificiales, El Perceptrón simple y multicapa.* Obtenido de Universidad de ZAragoza: https://zaguan.unizar.es/record/69205/files/TAZ-TFG-2018-148.pdf

Ayuso, R. (2017). *RELACIÓN ENTRE LA EVOLUCIÓN DE ÍNDICES BURSÁTILES Y VARIABLES MACROECONÓMICAS. ¿SE HA ALTERADO TRAS LA INTRODUCCIÓN DE MEDIDAS NO CONVENCIONALES DE POLITICA MONETARIA?* Obtenido de Repositorio Universidad Comillas de Madrid: https://repositorio.comillas.edu/rest/bitstreams/119119/retrieve

Bernanke, B. (2010). *Monetary Policy and the Housing Bubble.* Obtenido de https://www.federalreserve.gov/newsevents/speech/bernanke20100103a.htm

Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (11 de 12 de 2014). *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling.* Obtenido de https://arxiv.org/: https://arxiv.org/pdf/1412.3555.pdf?ref=hackernoon.com

David E. Rumelhart, G. E. (1986). Learning representations by back-propagating errors. *Nature*, 533-536.

Gertler, B. (1988). *Financial Structure and Aggregate Economic Activity: An Overview.* Obtenido de https://ideas.repec.org/a/mcb/jmoncb/v20y1988i3p559-88.html

Jaffee, D., & Stiglitz, J. (1990). *Credit Rationing.* Obtenido de http://faculty.haas.berkeley.edu/jaffee/papers/JaffeeStiglitz.pdf

Levine, & Zervos. (1996). *Stock Market Development and Long-Run Growth.* Obtenido de https://www.researchgate.net/publication/5217477_Stock_Market_Development_and_Long-Run_Growth

Manchado, M. C. (8 de 10 de 2018). *Predicción demanda eléctrica española.* Obtenido de eprints de la Universidad Complutense de Madrid: https://eprints.ucm.es/id/eprint/49444/

Minsky, H. (1992). *The Financial Instability Hypothesis, Working Paper nro 74.* Obtenido de https://www.ucm.es/data/cont/media/www/pag-41460/The%20Financial%20Instability%20Hypothesis%20Minsky.pdf

Minsky, H. P. (1974). *The Modeling of Financial Instability: An Introduction.* Obtenido de https://digitalcommons.bard.edu/hm_archive/467/

Rashid, T. (2017). *Make your oun neural networks.* ISBN-13: 978-1530826605.

Samuelson, P., & Nordhaus, W. (2003). *Economía.* Mc Graw Hill.

Sepp Hochreiter, J. S. (1997). *LONG SHORT-TERM MEMORY*. Obtenido de https://www.researchgate.net/publication/13853244_Long_Short-term_Memory/link/5700e75608aea6b7746a0624/download