



Universidad de San Andrés
Escuela de Administración y Negocios
Maestría en Finanzas

Aprendizaje automático en predicción de series financieras: caso Argentino

Autor: Hedo, Juan Pablo

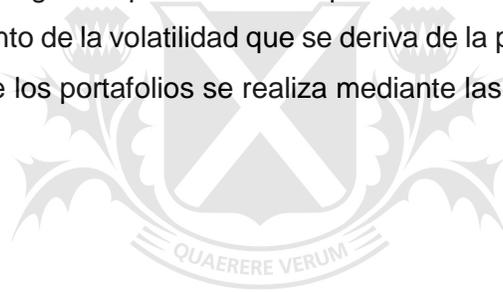
DNI: 32.813.247

Director de Trabajo Final de Graduación: Alejandro Loizaga

Buenos Aires, Noviembre de 2018

RESUMEN

La predicción sobre el futuro de los precios en los mercados financieros ha sido siempre una tarea de gran interés por su potencialidad en cuanto a las recompensas monetarias que podrían obtenerse y por los desafíos que implica en el mundo de la estadística y la matemática. El presente trabajo de graduación utiliza las series de precios de 16 activos del mercado argentino y se propone entrenar un algoritmo de aprendizaje automático denominado maquinas de vectores de soporte o SVM por sus siglas en ingles. Seguidamente, haciendo uso de las señales del algoritmo se elabora una estrategia de compra y venta de activos que conforman distintos portafolios que se evalúan contra un índice de referencia, en este caso el Merval 25. Los resultados arrojan la posibilidad de elaborar una estrategia superadora en términos de retornos al índice de referencia. Sin embargo, se destaca la incidencia negativa que tiene este tipo de estrategias respecto a los costos de transacción y al aumento de la volatilidad que se deriva de la predicción de los diferentes precios. La evaluación de los portafolios se realiza mediante las ratios de Información y de Sharpe.



Universidad de
San Andrés

Índice

1.	INTRODUCCIÓN.....	3
1.1.	<i>Objetivos</i>	5
1.2.	<i>Hipótesis</i>	5
2.	TÉCNICAS NO PARAMÉTRICAS PARA SERIES FINANCIERAS	6
2.1.	<i>Máquinas de Vectores de Soporte (SMV) en finanzas</i>	6
2.2.	<i>Redes neuronales para la identificación de patrones</i>	7
2.3.	<i>Otras técnicas no paramétricas en análisis técnico</i>	8
3.	METODOLOGÍA Y ANALISIS DE DATOS.....	10
3.1.	<i>Especificaciones del modelo</i>	10
3.1.1.	Variable a estimar	13
3.1.2.	Variables atributos del modelo	14
3.1.3.	Procesamiento de los datos	15
3.2.	<i>Selección y separación del conjunto de datos</i>	15
3.3.	<i>Estrategia financiera definida</i>	16
4.	RESULTADOS.....	18
4.1.	<i>Eficiencia de la predicción y tamaño de medias móviles</i>	18
4.2.	<i>Vector de señales de compra/venta</i>	19
4.3.	<i>Comparación contra el índice Merval 25</i>	19
4.4.	<i>Frecuencia de los datos y costos de transacción</i>	23
4.4.1.	Frecuencia mensual	23
4.4.2.	Frecuencia semanal	25
4.4.3.	Costos de transacción para diferentes frecuencias	27
5.	COMENTARIOS FINALES	30
6.	BIBLIOGRAFÍA	31
7.	ANEXO I.....	32
8.	ANEXO II	33
9.	ANEXO III	34

1. INTRODUCCIÓN

La predicción sobre el futuro de los precios en los mercados financieros ha sido siempre una tarea de gran interés por su potencialidad en cuanto a las recompensas monetarias que podrían obtenerse y por los desafíos que implica en el mundo de la estadística y la matemática. Usualmente gran parte de los esfuerzos en el uso de técnicas estadísticas para series de tiempo se restringen a la aplicación en escenarios controlados, con distribuciones de probabilidad conocidas -normales- y apelando a supuestos de linealidad de las series de datos. Sin embargo, en el caso particular de las series financieras de tiempo, la no estacionariedad, su naturaleza caótica y ruidosa ha vuelto particularmente difícil la estimación.¹

La hipótesis de mercados eficientes implica, en algún punto, que la predicción del precio en las series financieras es un esfuerzo sin sentido o al menos sólo posible en un momento efímero.² La inmediata reacción de los agentes del mercado a nueva información hará retornar el nivel de precios a su proceso de *camino aleatorio* anulando cualquier posibilidad de arbitraje para la obtención de ganancias.³ En dicho caso, la distribución de probabilidades para coincidir en la suba o baja del precio de una acción es comparable con lanzar una moneda, es decir un proceso puramente aleatorio. El debate continúa abierto y es posible encontrar tantos estudios que confirman como refutan dicha hipótesis de eficiencia.

El análisis técnico en las series de tiempo financieras, que dedica gran parte de sus esfuerzos en encontrar tendencias crecientes o decrecientes de corto plazo, la evidencia encontrada en el estudio de microestructuras de mercado que impactan en la formación de precios de los activos o la correlación entre los fenómenos de la macroeconomía y los mercados financieros; son algunas de las cuestiones que hace posible pensar que la predicción es en algún punto posible. Para que dicha predicción pueda traducirse en una estrategia de compra y venta de activos financieros, es preciso asumir entonces que no siempre las series de tiempo financieras siguen un proceso estacionario y que la tendencia y su variabilidad pueden variar a lo largo del tiempo y de acuerdo con diferentes ventanas temporales.

Kaufman (1987) en Yaser A. *et al* (1996) reconoce dos grandes enfoques para la predicción de precios de activos financieros. En primera instancia, el análisis fundamental o análisis por fundamentos, que postula el proceso formador de precios como consecuencia de la afectación de la oferta o la demanda, alternativamente. Aquí, se suponen factores económicos que impacten en una u otra y la predicción intenta medir marginalmente el impacto de estos fenómenos económicos en la conformación final del precio. En este sentido, un modelo predictor asumirá, por ejemplo, la existencia de un parámetro que explica al menos parcialmente, el efecto de una sequía en el precio de los *comodities* agropecuarios. Lo cual en términos teóricos haría aumentar el precio de estos y por consiguiente una ocasión para comprar futuros agrícolas.⁴

Por otro lado, el análisis técnico es un enfoque que visualiza sólo la serie de precios realizando, principalmente, un estudio gráfico para identificar patrones y tendencias. No utiliza ninguna información económica externa a los precios ya que asume que toda la

¹ Deboeck, G.. Trading on the edge: neural, genetic, and fuzzy systems for chaotic financial markets. Vol. 39. John Wiley & Sons, 1994.

² Abu-Mostafa, Yaser S., and Amir F. Atiya. Introduction to financial forecasting. Applied Intelligence 6.3 (1996): 205-213.

³ Fama, Eugene F. "Efficient Capital Markets: A Review of Theory and Empirical Work." The Journal of Finance, vol. 25, no. 2, 1970, pp. 383-417. JSTOR, JSTOR, www.jstor.org/stable/2325486.

⁴ Abu-Mostafa, Yaser S., and Amir F. Atiya. Introduction to financial forecasting. Applied Intelligence 6.3 (1996): 205-213.

información requerida para la formación de precios se encuentra implícita en la serie histórica de precios. En cuanto al uso de herramientas cuantitativas, el análisis de medias móviles y de regresión son las dos más usadas. El primero da una señal de tendencia alcista si el precio promedio de los activos en el corto plazo es superior que el promedio de los precios en un plazo más largo. En el segundo, sucesivas líneas se trazan sobre los puntos de precios más cercanos para identificar tendencias al alza o a la baja.

El desarrollo de técnicas matemáticas y estadísticas para la predicción también puede caracterizarse en dos grandes vertientes según Lijuan et al (2001); el análisis univariado y el análisis multivariado. Mientras que en el primero los modelos predictivos utilizan exclusivamente como resultado a la serie de precios a predecir, en los multivariados la misma serie predicha puede utilizarse como predictoras dentro de un conjunto mayor de variables explicativas. El mayor referente de los primeros es el modelo autorregresivo ARIMA, del tipo paramétricos y cuya sofisticación está principalmente ligada a la obtención de parámetros eficientes e insesgados para explicar los movimientos de la serie de tiempo, aun cuando no necesariamente sean eficientes a la hora de predecir el futuro de los precios de activos financieros. Estos modelos asumen que la serie es lineal y estacionaria, cuestión que podría contradecir la naturaleza de las series financieras de precios.

Allí es donde los enfoques multivariados encuentran un lugar importante en la predicción de activos a partir del desarrollo de las denominadas redes neuronales. En términos generales, estos métodos pueden utilizar grandes volúmenes de información y de diferente procedencia siendo concordante con la naturaleza multidimensional de los fenómenos financieros. Son esencialmente no paramétricos y no asumen supuestos sobre la estacionariedad o linealidad de las series temporales. Sin embargo, usualmente son excesivamente sensibles a ruidos en la serie de datos restringiendo su capacidad de generalización; es decir, es bastante común caer en procesos de '*sobre-ajuste*' a los datos en este tipo de modelización. Dada la caracterización del proceso a través de una red neuronal, es posible desembocar en parámetros que pueden ser sesgados, pero contar, a la vez, con una alta eficiencia en la predicción de fenómenos.⁵

Otro enfoque multivariado y que ha sido optimizado para series de tiempo por Vapnik (1998)⁶, y es denominado *Maquinas de Vectores de Soporte* (SVM por sus siglas en inglés). Es una de varias técnicas de aprendizaje automático que logra minimizar el error de predicción para un conjunto de datos de prueba distinto al utilizado para el entrenamiento del modelo. Su objetivo es minimizar el error de generalización usualmente presente en otras técnicas de modelización por aprendizaje automático.⁷⁸

En el caso particular de este trabajo, se explorará el uso de esta última técnica de para la elaboración de una estrategia financiera comercial consistente con el aprovechamiento de *momentum* o tendencias de corto plazo. Puntualmente, se utiliza la serie de precios ajustados por dividendos de un *portfolio* de acciones idéntico al Merval 25. El periodo comprendido entre 2007 y 2016 se utilizó como entrenamiento del algoritmo mientras que las medidas de eficiencia en la predicción fueron calculadas para el periodo de 2016 a 2018. Adicionalmente, la evaluación de la estrategia se realizó a través de la comparación de retornos con el índice Merval 25 dentro del periodo de predicción. La serie de precios utilizada es de temporalidad diaria.

⁵ Tay, Francis EH, and Lijuan Cao. Application of support vector machines in financial time series forecasting. *omega* 29.4 (2001): 309.

⁶ Vapnik, V. *Statistical learning theory* new york. NY: Wiley (1998).

⁷ Müller, K-R., et al. Predicting time series with support vector machines. *International Conference on Artificial Neural Networks*. Springer, Berlin, Heidelberg, 1997.

⁸ Mukherjee, Sayan, Edgar Osuna, and Federico Girosi. Nonlinear prediction of chaotic time series using support vector machines. *Neural Networks for Signal Processing [1997] VII. Proceedings of the 1997 IEEE Workshop. IEEE, 1997.*

1.1. Objetivos

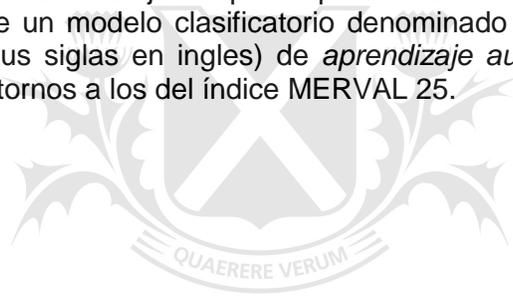
El presente trabajo tiene como objetivo elaborar un algoritmo de clasificación de *aprendizaje automático* denominado *Maquinas de Vectores de Soporte* (SMV) que permita identificar estrategias de compra o venta de acciones del panel Merval 25.

Objetivos específicos:

- Predecir si el precio de un activo estará más alto o bajo para de manera diaria y evaluar la eficiencia de la predicción en cada caso.
- Diseñar una estrategia financiera comercial basada en la predicción del modelo, decidiendo cuándo es el mejor momento para la compra o la venta de activos del panel líder del Merval.

1.2. Hipótesis

La hipótesis central del trabajo es que es posible diseñar una estrategia financiera comercial a través de un modelo clasificatorio denominado *Maquina de Vectores de Soporte* (SMV, por sus siglas en inglés) de *aprendizaje automático* y que dé como resultado mayores retornos a los del índice Merval 25.



Universidad de
San Andrés

2. TÉCNICAS NO PARAMÉTRICAS PARA SERIES FINANCIERAS

La incursión en técnicas no paramétricas para la predicción de series de precios ruidosas ha sido detallada en la introducción del trabajo. A continuación, se presentan algunas aplicaciones en distintos aspectos financieros y, especialmente, el caso de las redes neuronales y de vectores de soporte. Al finalizar, se presentan técnicas de suavizado de series y de identificación de patrones en las series de tiempo.

2.1. Máquinas de Vectores de Soporte (SMV) en finanzas

El algoritmo de Vectores de Soporte (SMV) sirve principalmente para la resolución de problemas de clasificación. Fue en la década del noventa, de la mano del trabajo realizado por Vapnik en 1998⁹, cuando se popularizó su uso luego de que se introdujeron las funciones *Kernel* y el suavizado de los márgenes para la resolución de problemas de mayor complejidad.

La aplicación de SVM en problemas financieros de predicción fue implementado por Cao and Tay (2001)¹⁰ en la predicción del mercado de futuros de Chicago y su metodología fue comparada con el uso de Redes Neuronales Autorregresivas (RNA), encontrándose una mejor performance a las evidenciadas por RNA.

En la misma línea Kim (2003)¹¹, utiliza SVM para predecir el índice diario compuesto de Korea y es comparado contra una medida de comparación realizada con Redes Neuronales Autorregresivas (RNA). El estudio comprobó también que SVM debe ser considerado como un método de buena performance en la predicción de series de tiempo financieras. También Huang et al. (2004)¹², realizaron un estudio experimental para predecir el movimiento semanal del índice NIKKEI 225, nuevamente SVM demostró mejores predicciones que otros métodos discriminantes como el análisis discriminante lineal, el análisis discriminante cuadrático y las redes neuronales autorregresivas.

En cuanto al uso de funciones radiales para el método SVM, Muller et al (1997)¹³ encontraron buenas performances de predicción en diferentes series de tiempo simuladas (ruido uniforme generado por la ecuación Mackey Glass y la serie denominada *Santa Fe competition* -set D). Su especificación y efectividad para resolver problemas de clasificación de series temporales se detalla en el capítulo metodológico.

⁹ Vapnik, V. Statistical learning theory new york. NY: Wiley (1998).

¹⁰ Tay, Francis EH, and L. J. Cao. Modified support vector machines in financial time series forecasting. *Neurocomputing* 48.1-4 (2002): 847-861.

¹¹ Kim, Kyoung-jae. Financial time series forecasting using support vector machines. *Neurocomputing* 55.1-2 (2003): 307-319.

¹² Huang, Wei, Yoshiteru Nakamori, and Shou-Yang Wang. Forecasting stock market movement direction with support vector machine. *Computers & Operations Research* 32.10 (2005): 2513-2522.

¹³ Müller, K-R., et al. Predicting time series with support vector machines. *International Conference on Artificial Neural Networks*. Springer, Berlin, Heidelberg, 1997.

2.2. Redes neuronales para la identificación de patrones

El reconocimiento de patrones financieros se enmarca en un proceso esencialmente estadístico. En este sentido, es que el uso de redes neuronales permite a través de la extracción de 'probabilidades a posteriori' dado una serie de probabilidades condicionales predecir el movimiento futuro. El verdadero valor predictivo de una red es entonces el uso de probabilidades condicionales de estadística bayesiana, permitiendo la incorporación sucesiva de nueva información relacionada con el fenómeno para la actualización de las probabilidades 'posteriores'.

Entendiendo la idea detrás de una red neuronal, es preciso describir su estructura. De acuerdo con Haid et al (2005)¹⁴, una red contiene (a) elementos de procesamiento o 'neuronas', (b) conexiones entre dichos elementos, (c) ponderadores asociados a dichos elementos y (d) función de activación.

Pueden utilizarse dos grandes tipos de redes neuronales: (a) Redes de alimentación hacia adelante, que no forman un ciclo interno entre las capas y (b) redes recurrentes o autorregresivas que pueden formar ciclos entre las capas, esto es las capas posteriores pueden alimentar capas anteriores. Estas últimas son adecuadas para la resolución de problemas de información secuencial o de series de tiempo.

Algunos ejemplos de aplicaciones para series financieras son la identificación de estrategias para los mercados de acciones¹⁵ (*compra/venta con identificación de tendencias de corto plazo*). Se utiliza una serie de redes neuronales para la identificación de tendencias de corto plazo que presenten una oportunidad de compra o venta de activos.

La aplicación práctica del artículo de Sethi et al (2014), se hizo con 100 acciones del S&P. La red fue entrenada 250 días con 750 días anteriores como muestra. Los resultados del portafolio dan anualizados y en promedio para los últimos 7 años 16,7% versus un S&P 500 que se mantuvo cercano a cero si se lo mira punta a punta. Otro ejemplo es la identificación de estrategias en mercados de monedas (*compra/venta entre monedas*). Las estrategias están orientadas usualmente al intra-diario o a la evaluación de los retornos de alta frecuencia en dichos mercados (Yao et al, 2000)¹⁶.

De acuerdo con los estudios de Yao et al¹⁷, la aplicación de redes neuronales para el pronóstico de las tasas de retorno entre el Dólar americano y otras cinco monedas (Yen, Marco alemán, Libra esterlina, Franco suizo y Dólar australiano) mostraron resultados más precisos que la aplicación de modelos con supuestos de eficiencia de mercado e incluso de métodos provenientes del análisis técnico. El experimento hace uso de una serie de indicadores de análisis técnico.

- El primer indicador que utilizan los autores refiere al R/S (análisis de re-escalamiento de rango) que permite identificar de una serie aleatoria de una serie fractal (o de aquella serie que puede parametrizarse a través de una distribución conocida). El principal objetivo de este indicador es el reconocimiento de la tendencia y la persistencia de la misma. En este caso

¹⁴ Hamid, Shaikh A., and Abraham Habib. Can neural networks learn the Black-Scholes model? A simplified approach. (2005).

¹⁵ Sethi, Mininder, Philip Treleaven, and Sebastian Del Bano Rollin. Beating the S&P 500 index—A successful neural network approach. Neural Networks (IJCNN), 2014 International Joint Conference on. IEEE, 2014.

¹⁶ Yao, Jingtao, and Chew Lim Tan. A case study on using neural networks to perform technical forecasting of forex. Neurocomputing 34.1-4 (2000): 79-98.

¹⁷ IDEM 17

puntual, sirve para identificar los efectos de memoria a largo plazo en las tasas de cambio a lo largo de cierto período.

- El ratio R/S, esto es de R en función al desvío standard de la serie original, puede ser estimado a través del estimador $\widehat{R/S} = N^h$, siendo $h = \frac{\log(R/S)}{\log(N)}$ siendo h un valor entre 0 y 1. Los valores típicos del exponente son $H= 0.5$, $0 \leq H \leq 0.5$ y $0.5 \leq H \leq 1$ que describen eventos aleatorios y por ende eventos no correlacionados. El segundo caso, muestra alta volatilidad con alta reversión a la media. El tercer caso, es aquel que indica persistencia o evidencia de tendencia; esto es efectos de largo plazo. De alguna manera, cuando más cercano sea H a cero mayor será el ruido y la volatilidad (*camino aleatorio*) y cuanto mayor a 1 menor es la cantidad de ruido y la factibilidad de encontrar tendencias.

Los resultados encontrados por los autores (Yao et al, 2000) muestran una mayor precisión que modelos de alta frecuencia como los ARIMA. Asimismo, las estrategias diseñadas mostraron mejores performances que las dos estrategias básicas de compra/venta y seguimiento de tendencia. En términos de críticas, el principal inconveniente refiere a la poca memoria de la red y a cierta falta de adaptabilidad a situaciones puntuales. Esto último, obliga a reentrenar la red con nuevas series cada 20 semanas, así como la necesidad de agregar nuevos parámetros para flexibilidad de la red deberían ser incorporados (volatilidad de la serie, volumen operado, etc.)

2.3. Otras técnicas no paramétricas en análisis técnico

Utilizando el análisis técnico gráfico, distintos autores han intentado probar la fundamentación estadística y matemática de los diferentes patrones que usualmente se utilizan en el análisis técnico gráfico. Dado que este utiliza la geometría y otras técnicas de reconocimiento de patrones que son principalmente visual, y las finanzas cuantitativas utilizan mayoritariamente herramientas matemáticas, de probabilidad y estadísticas¹⁸. El desafío es entonces eliminar la brecha entre ambos enfoques ofreciendo un acercamiento sistemático y científico para la práctica del análisis técnico. El objetivo ulterior del análisis técnico es la identificación de comportamientos regulares extrayendo patrones de los datos de series de precio. En muchos casos, el ojo humano puede extraer.

- Estimación suave: La utilización de técnicas no paramétricas se desprende del supuesto fundamental del análisis técnico que los precios envuelven no linealidad a lo largo del tiempo y que dichas 'no linealidades' contienen ciertas regularidades o patrones.

La construcción de una función 'suave' para aproximar la serie de tiempo es un paso fundamental:

$$P_t = m(X_t) + \varepsilon_t \quad t = 1, \dots, T$$

De esta manera, los precios son la suma de patrones no lineales $m(X_t)$ y ruido blanco y dichos patrones pueden ofrecer información relevante de la función suave $m(\cdot)$.

¹⁸ Lo, Andrew W., Harry Mamaysky, and Jiang Wang. Foundations of technical analysis: Computational algorithms, statistical inference, and empirical implementation. The journal of finance 55.4 (2000): 1705-1765.

Para capturar dicha información de manera sistemática es preciso desarrollar un algoritmo de reconocimiento de patrones.

2.3.1. *Suavizado*: uno de los métodos más comunes para la estimación de estos patrones es el suavizado, que consiste en reducir los errores promediando la data de formas diversas: regresiones Kernel, expansión ortogonal de la serie, etc. Un ejemplo de cómo promediando la serie se puede obtener un estimador de la función $m(\cdot)$ en un determinado punto X_0 sería el siguiente:

$$\hat{m}(x_0) = m(x_0) + \frac{1}{n} \sum_{i=1}^n \varepsilon_t^i$$

En otras palabras, si $m(\cdot)$ es lo suficientemente suave, entonces en un entorno pequeño alrededor de X_0 , $m(X_0)$ estará constantemente cerca y podría ser estimado tomando un promedio de los precios P_t que corresponden a esos patrones X_t cercanos a X_0 . Cuanto más cerca estén los X_t al valor X_0 más cercano será el promedio de los correspondientes P_t a $m(X_0)$.

2.3.2. *Regresión Kernel*

En el caso de la regresión Kernel, la función ponderada w_t enunciada anteriormente se obtiene, en vez de la implementación ad-hoc del tamaño del entorno, a través de una función de probabilidad $K(t)$, también llamada kernel:

$$w_{t,h}(x) = K_h(x - X_t) / g_h(x) \text{ con } g_h(x) = \frac{1}{T} \sum_{t=1}^T K_h(x - X_t)$$

Si h es muy pequeña, el promedio se hará en un entorno relativamente pequeño y por el contrario si h es muy grande. Elegir el correcto nivel de h es nuevamente el proceso crítico

2.3.3. Selección de la banda: aquí se utiliza Nadaraya-Watson kernel estimator

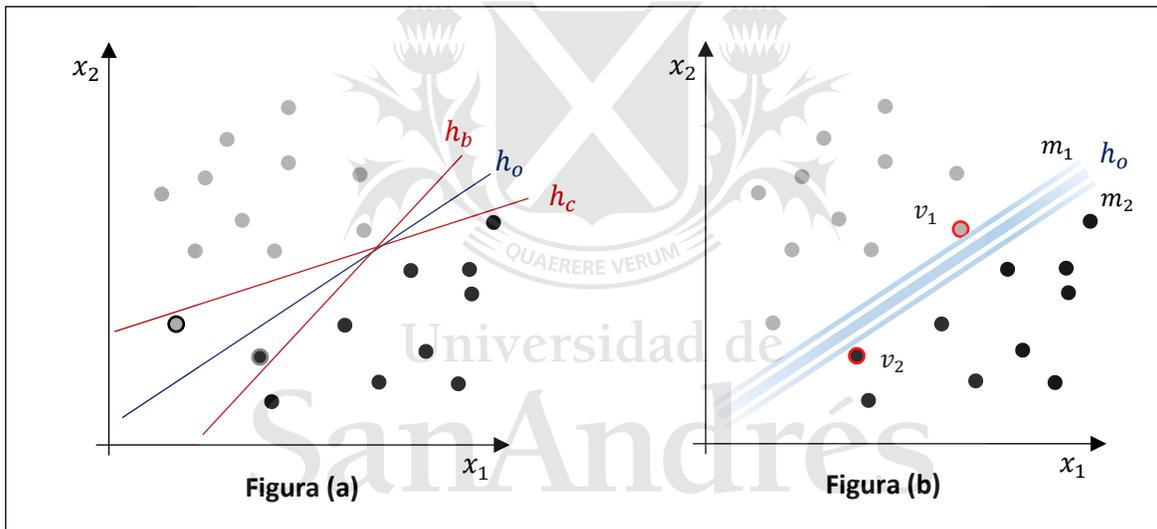
$$Y_t = \sin(x_t) + 0,5 \varepsilon Z_t \quad \varepsilon Z_t \sim N(0,1)$$

La selección de h se desprenderá de la minimización de la función de validación cruzada; no obstante, usualmente se utiliza $h = 0,3$ como el valor correcto para definir el entorno correcto. El proceso es ad-hoc.

3. METODOLOGÍA Y ANALISIS DE DATOS

3.1. Especificaciones del modelo

El algoritmo de vectores de soporte (SMV) utilizado tiene como objetivo encontrar un hiperplano que pueda dividir dos clases de observaciones. Suponiendo como ejemplo un conjunto de observaciones $y \in [0,1]$ donde [1] indica que un precio de un día y activo determinado subió con respecto a su precio anterior y [0], el caso contrario. Si se quisiera clasificar en $[0,1]$ las observaciones con dos variables como, por ejemplo x_1 la media móvil del tamaño del *momentum* de los últimos n días y x_2 la proporción de subidas de los últimos n días, la mejor forma que encontrará SVM para la clasificación de las dos clases será una recta. Sin embargo, tal como se observa en Figura (a), el problema a resolver será elegir aquella recta que no deje una observación clasificada de manera incorrecta. Es decir, deberá elegirse h_o en detrimento de las opciones de h_b o h_c .



La forma de resolución de este problema se realiza a través de la maximización de márgenes a las diferentes opciones de recta posible. De esta forma, como se observa en la Figura (b) aquella recta que maximice la distancia desde la línea discriminante hasta el primer punto más cercano será elegida como la óptima. Cuando el modelo se ajusta, la línea discriminante es la que se encuentra en el medio mientras que las líneas laterales representan los límites del margen. Al mismo tiempo, sólo algunos puntos del plano importan para elegir la opción correcta y son aquellos más cercanos a la solución límite; estos puntos son denominados vectores de soporte ($v_1; v_2$) y son los que dan nombre al método 'Maquinas de Vectores de Soporte'.

La creación de la frontera de separación óptima es en este caso un problema lineal resuelto con dos atributos:

$$w_0 + w_1x_1 + w_2x_2 = h_o$$

donde h_o es la recta discriminante óptima, w_i son parámetros del hiperplano y x_i los vectores de atributos.

En su forma general, con un vector de atributos n-dimensional $n = (x_1, x_2, \dots, x_n)$; el hiperplano lineal que funciona como frontera entre ambas categorías de observaciones es de la siguiente forma:

$$h_o = w_0 + w_1x_1 + \dots + w_nx_n = w_0 + \sum_{i=1}^n w_ix_i$$

donde h_o es la recta discriminante óptima, x_i los atributos y w_i los parámetros que determinan el hiperplano.

Hasta aquí, el hiperplano es aplicable cuando se estudia un problema de clasificación lineal. No obstante, los problemas de clasificación suelen ser no lineales. En este caso, el algoritmo de vectores de soporte se vale de transformaciones escalares de los datos que permitan encontrar nuevamente un hiperplano lineal que sirva de frontera de separación de las observaciones transformadas. Supongamos el problema de clasificación como el que muestra en la Figura (d), el mismo se encuentra en un espacio $IR \rightarrow 2$ y, a través de una función $K(x_1, x_2)$, es posible transformarla al espacio $IR \rightarrow 3$ como el que se muestra en la Figura (e).

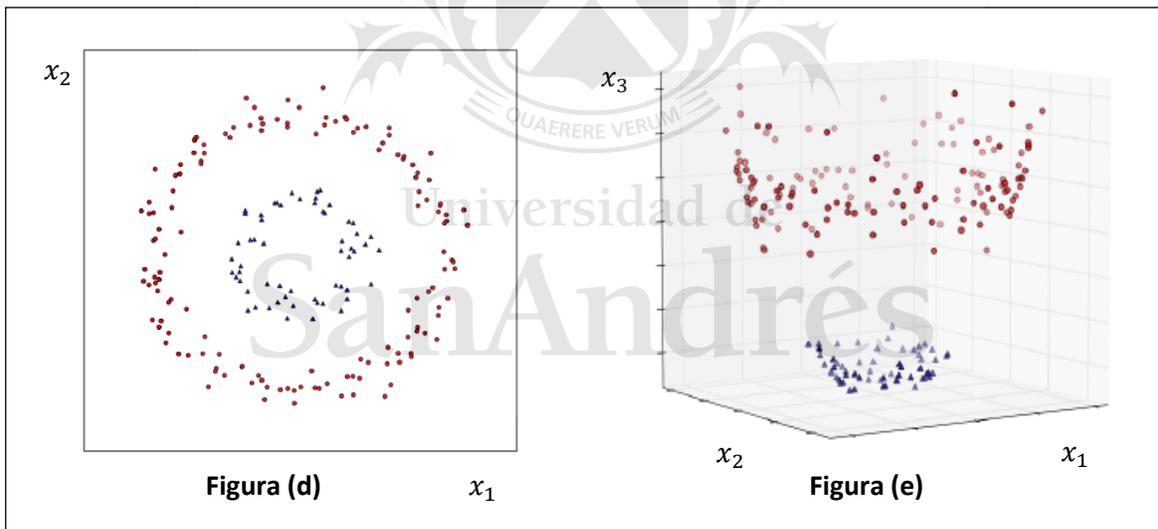


Fig. (d) y (e) - Kim, E. (2013). Everything you wanted to know about the kernel trick. URL: http://www.eric-kim.net/eric-kim-net/posts/1/kernel_trick.html.

En este caso, la transformación a un espacio de orden mayor mediante la función $K(x_1, x_2)$ permite, en $IR \rightarrow 3$, encontrar una solución lineal con un hiperplano discriminante a un problema originalmente no lineal. El hiperplano se muestra en la Figura (f) y la solución en $IR \rightarrow 2$ al problema de clasificación no lineal se muestra en la Figura (g). La forma funcional del hiperplano queda expresada entonces de la siguiente manera para la resolución de problemas no lineales:

$$h_o = b + \sum_{i=1}^n \alpha_i y_i K(x_{(i)}, x)$$

donde, b y α_i son parámetros que ajustan al hiperplano y K es la función de transformación dimensional que se encuentra ponderada por la variable de resultados. En otras palabras $\alpha_i y_i$ serán los parámetros del hiperplano óptimo.

La importancia del algoritmo de máquinas de soporte es que convierte un problema de clasificación difícil de resolver en uno más sencillo: encontrar la mejor transformación escalar de los datos para hallar un hiperplano lineal que se ajuste a la solución de clasificación.

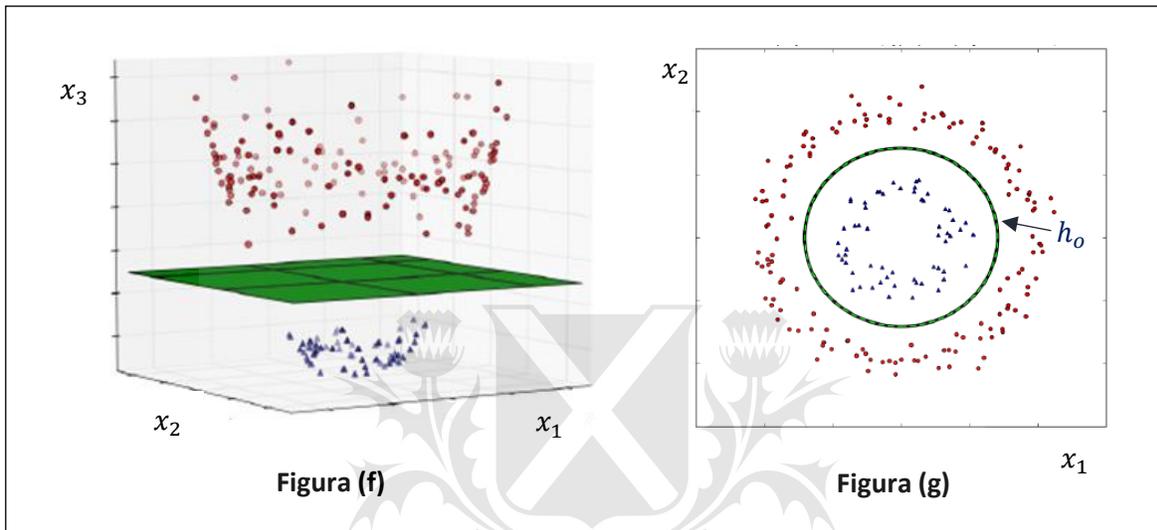


Fig. (f) y (g) - Kim, E. (2013). Everything you wanted to know about the kernel trick. URL: http://www.eric-kim.net/eric-kim-net/posts/1/kernel_trick.html.

Sin embargo, el SMV se vale de una sola especie de transformación escalar y son las denominadas funciones Kernel. Estas funciones en particular realizan el producto escalar de a pares de los distintos vectores de atributos y las mas comunes son las polinómicas, las radiales o las sigmoide. En el caso particular de este trabajo, la función Kernel elegida es la función en base radial (SVM RBF Kernel). Siguiendo lo expuesto por Müller¹⁹, este tipo de funciones se adecúan mejor a la predicción con series temporales y la generalización se encuentra expresada a continuación:

$$K_{RBF}(x, x') = \exp[-\gamma \|x - x'\|^2]$$

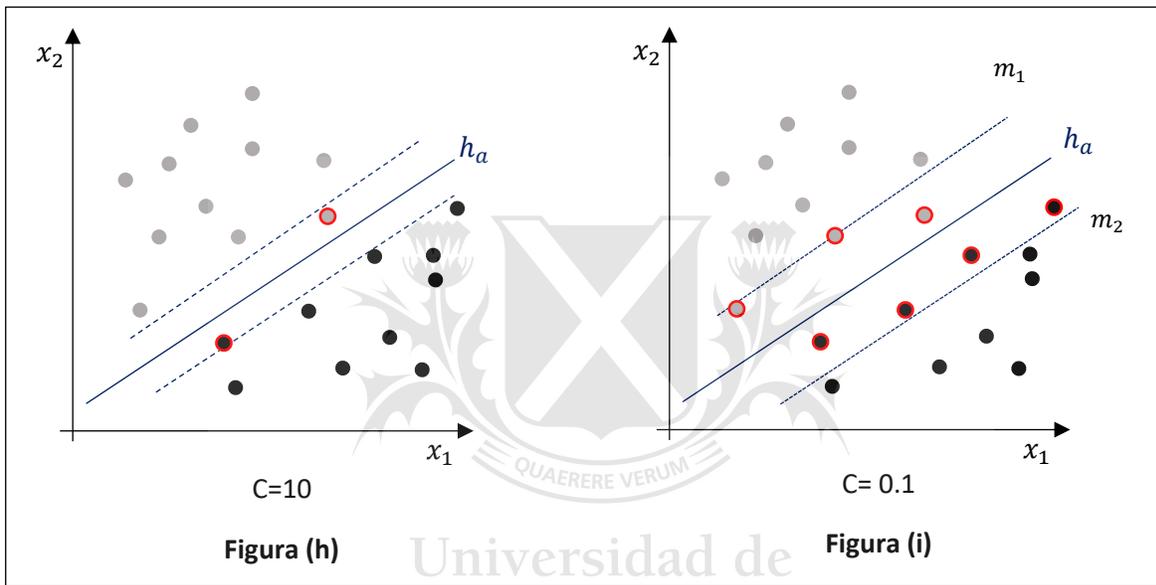
donde $\|x - x'\|^2$ representa la distancia Euclídea cuadrática entre los vectores de soporte de la clase x y x' . El parámetro γ es uno del tipo libre de ajuste del modelo en función a la volatilidad y es siempre mayor a 0.

Aquí es preciso aclarar, que mayores valores del parámetro γ lograrán soluciones más ajustadas a los datos, pero con menor poder de generalización. La elección optima de este parámetro es imprescindible para evitar *sobre ajustar a los datos* en la especificación del modelo y tener problemas para su generalización.

¹⁹ Müller, K-R., et al. Predicting time series with support vector machines. International Conference on Artificial Neural Networks. Springer, Berlin, Heidelberg, 1997.

Finalmente, otro problema que debe sortear el algoritmo es que los límites de la solución óptima o bien no se ajusten a una función conocida o directamente no sea posible hallarla. Es usual encontrarlo en conjuntos de datos ruidosos, por lo que incorporarse un parámetro adicional que permita que algunos puntos del plano puedan no estar clasificados de la manera correcta. Este parámetro “C” controla entonces el compromiso entre la complejidad del modelo y el número de observaciones no separables. Su imputación es también libre y debe ser definida a través de validación cruzada al igual que parámetro γ .

En términos prácticos, este último es comparable con la inversa del ancho de los márgenes que rodean la línea discriminante; valores más altos de “C” darán márgenes más angostos y viceversa -ver Figuras (h) e (i).



Este parámetro, también afecta el ajuste de los datos y es quien realiza la compensación entre sesgo y varianza del modelo. Márgenes más angostos se ajustarán más restrictivamente la línea discriminante, pero afectarán la generalización del modelo.

En el caso particular de este trabajo, se realizaron las siguientes transformaciones de las variables para entrenar el algoritmo de vectores de soporte:

3.1.1. Variable a estimar

La variable por estimar es también una transformación binaria de la serie de precios compatible con el modelo clasificador SMV. Es decir, toma valor 0 si el precio de la acción en $t=1$ es menor o igual al valor de la acción en $t=0$; mientras que tomará el valor 1 si el precio en $t=1$ es mayor que el precio en $t=0$. Esta variable es calculada para cada especie que conforma el portafolio de activos.

$$y_{j,i}(0,1) \begin{cases} 0, & p_{j,i} \geq p_{j,i+1} \\ 1, & p_{j,i} < p_{j,i+1} \end{cases}$$

Siendo $p_{j,i}$ el precio en el momento i para la acción j .

3.1.2. Variables atributos del modelo

En cualquier caso, la efectividad de la predicción del SMV dependerá de las variables que se elijan para segmentar o clasificar las observaciones. En el caso de este trabajo, la serie de precios de acciones se utilizan para el entrenamiento del modelo de manera transformada. En línea con el trabajo de Roselio (2014)²⁰, se utilizan indicadores de análisis técnico como el *momentum*, las medias móviles y la función ROC para tasas de cambio. En cada una de las funciones, se encuentran el parámetro “*k*” que es aquel que define la ventana de tiempo para el cálculo de los distintos indicadores.

1. Media móvil de *k* días para *momentum* diario (*i*)

$$X1_i = \sum_{i=1}^k \frac{p_{j,i+1} - p_{j,i}}{k}$$

Siendo $p_{j,i}$ el precio en el momento *i* para la acción *j* y *k* una ventana temporal expresada en días.

2. Porcentaje de subas de *k* días para precios diarios (*i*)

$$X2_i = \sum_{i=1}^k \frac{\begin{cases} 0, & p_{j,i} \geq p_{j,i+1} \\ 1, & p_{j,i} < p_{j,i+1} \end{cases}}{k}$$

Siendo $p_{j,i}$ el precio en el momento *i* para la acción *j* y *k* una ventana temporal expresada en días.

3. Media móvil de *k* días para tasa de cambio de precios diarios (*i*)

$$X3_i = \sum_{i=1}^k \frac{(p_{j,i+1} - p_{j,i}) / p_{j,i}}{k}$$

Siendo $p_{j,i}$ el precio en el momento *i* para la acción *j* y *k* una ventana temporal expresada en días.

Los tres indicadores visualizan diariamente lo ocurrido con el tamaño del *momentum* diario (X1), con el porcentaje de subas (X2) y con los retornos de *k* días anteriores (X3). Las tres cuestiones son utilizadas por el modelo SVM para estimar diariamente el precio

²⁰ Rosillo, Rafael, Javier Giner, and David De la Fuente. "Stock market simulation using support vector machines." *Journal of Forecasting* 33.6 (2014): 488-500.

del día siguiente. En el caso de este trabajo, la selección de la ventana para las medias móviles es seleccionada de acuerdo con la eficiencia en la predicción del modelo.

3.1.3. Procesamiento de los datos

El procesamiento de los datos fue realizado con el lenguaje Python. En el mismo, se encuentra el paquete gratuito **Scikit-Learn**²¹ con la modelización de Maquinas de Vectores de Soporte (SMV, por sus siglas en inglés). Al mismo tiempo, se utilizan los módulos de Cross Validation y de Sklearn Metrics para la obtención de medidas de eficiencia de predicción. Otros paquetes de Python utilizados fueron Pandas²², Numpy²³ y Matplotlib²⁴; todos de acceso libre y gratuito.

El código de procesamiento en lenguaje Python fue elaborado en un entorno de Anaconda, específicamente en Jupyter Notebook.

3.2. Selección y separación del conjunto de datos

El periodo seleccionado en este trabajo es 2007-2018. En el mismo se tomó la serie de precios ajustados por pago de dividendos de las siguientes acciones del panel Merval 25. Sólo se consideran aquellas que estando actualmente en dicho panel también lo estuvieron durante todo el periodo considerado. El detalle se muestra en la Tabla (a).

Tabla (a)

Especie	Nombre
ALUA	Aluar
APBR	Petroleo Brasileiro
BMA	Banco Macro
COME	Sociedad Comercial del Plata
EDN	Edenor
FRAN	BBVA Banco Francés
GGAL	Grupo Financiero Galicia
METR	Metrogas
MIRG	Mirgor
PAMP	Pampa Energía
TGNO4	Transportadora Gas del Norte
TGSU2	Transportadora Gas del Sur
TRAN	Transener
TS	Tenaris
TXAR	Ternium Argentina Sa
YPFD	YPF

²¹ <http://scikit-learn.org/stable/>

²² <https://pandas.pydata.org/>

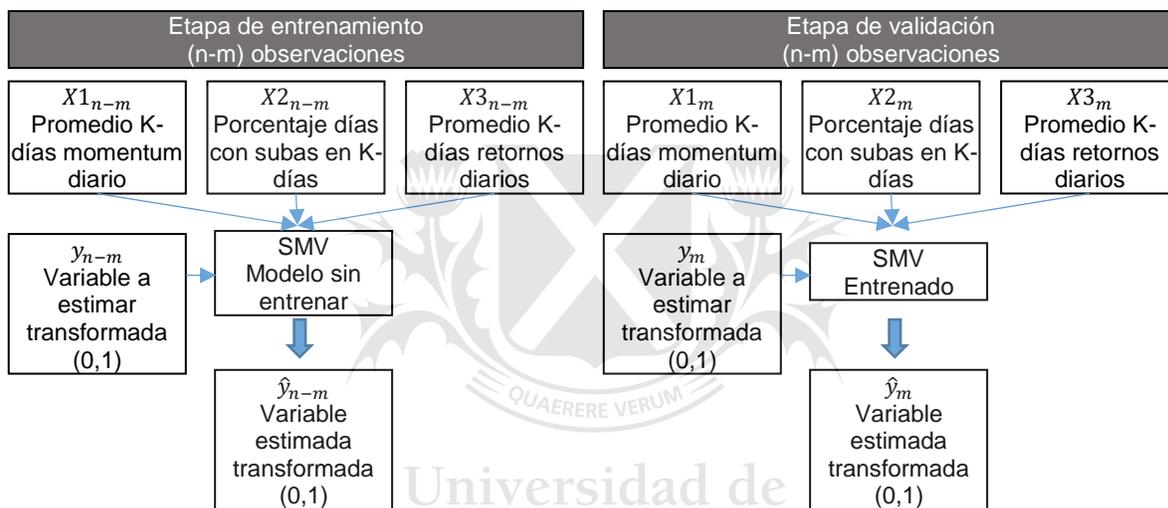
²³ <http://www.numpy.org/>

²⁴ <https://matplotlib.org/>

Es preciso aclarar, que se toma el 75% de los datos aproximadamente para realizar el entrenamiento del algoritmo, mientras que el 25% restante se utilizó para validación de la eficiencia de predicción del modelo. Esto da como resultado un periodo de entrenamiento desde enero 2007 hasta el 10 de diciembre de 2015 y de validación desde el 11 de diciembre de 2015 hasta noviembre 2018 (coincidente con el cambio de gobierno y el levantamiento del cepo cambiario).

De esta manera, el flujo de entrenamiento y validación del modelo queda conformado de la siguiente forma, donde (m) es el tamaño en días del conjunto de datos de validación del modelo y ($n-m$) el de entrenamiento. Las etapas de validación y de entrenamiento se encuentran diagramadas en la Figura (j).

Figura (j)



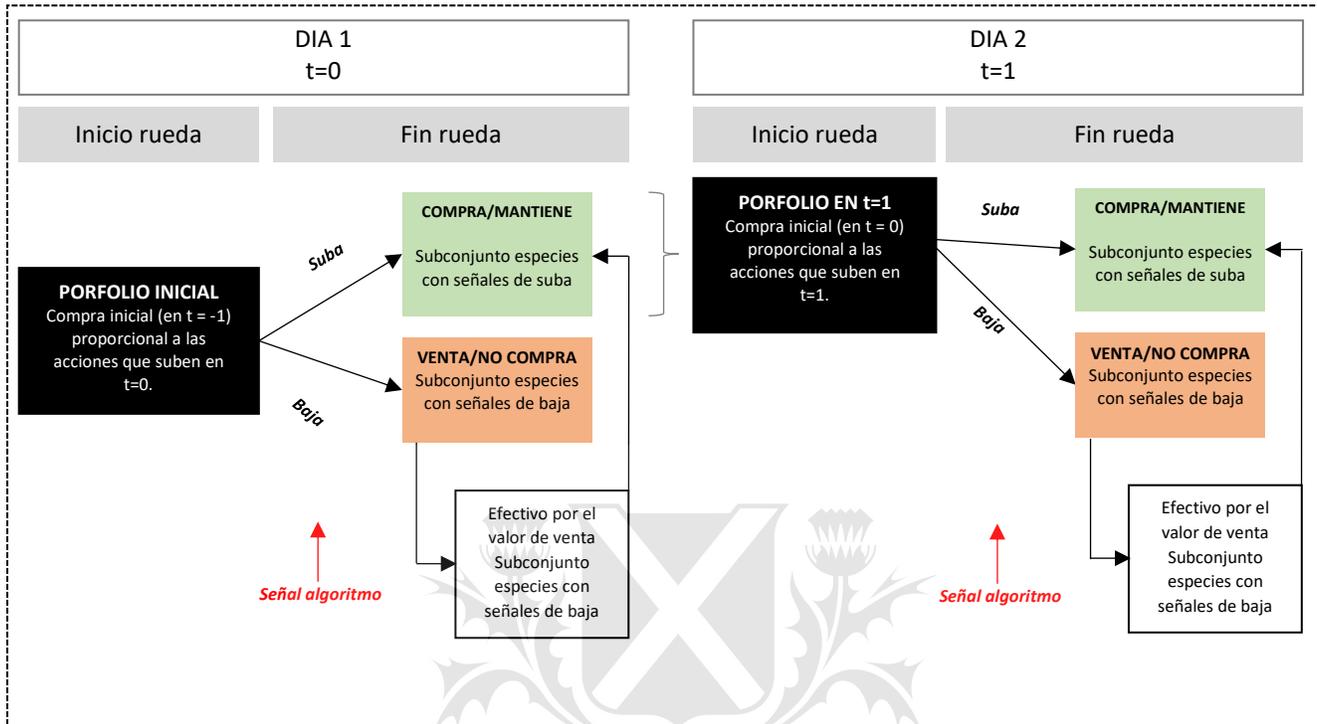
En este caso, el porcentaje de aciertos se obtiene comparando la variable y_m del conjunto de validación con la variable \hat{y}_m del mismo periodo m .

3.3. Estrategia financiera definida

La estrategia elaborada es del tipo activa diaria (compra/venta diaria -*buy and selling daily trading*). El método consiste en comprar y vender un subconjunto de activos dentro del mismo día y mantener otro en cartera hasta el otro día. Esto implica el cierre de posiciones en algunos activos y el mantenimiento de otros, en función de las diferentes señales de suba o baja del precio. También implica la reinversión de un sobrante en efectivo de las acciones con señal de baja y se usará a partir de $t=1$ en la compra de acciones con señales de suba.

En $t=-1$ se invierte la suma de 1 millón ARS en el set de acciones que el algoritmo predice que subirán en $t=0$. En la Figura (k) se ejemplifica el proceso típico diario de la estrategia

Figura (k)



La estrategia define los siguientes supuestos:

- i. Si la predicción al cierre del día es que un determinado activo va a subir al otro día se mantiene en el portafolio.
- ii. Si la predicción al cierre del día es que un determinado activo va a bajar al otro día, se vende y se redistribuye equi-proporcionalmente en especies que van a subir.
- iii. Al inicio de cada rueda se tiene un portafolio inicial de acciones; no se mantienen posiciones en efectivo.
- iv. Se consideran costos de transacción.

4. RESULTADOS

La fecha de la división del conjunto de datos, como se dijo anteriormente, es el 10 de diciembre de 2015, dejando 709 observaciones en el *conjunto de datos de validación* para cada especie. Esto implica que el 74.5% de las observaciones fueron utilizadas para el entrenamiento del algoritmo.

4.1. Eficiencia de la predicción y tamaño de medias móviles

De esta forma, el puntaje que se muestra en la Tabla (b), corresponde a la proporción de aciertos respecto a la suba o la baja diaria, dentro del conjunto de datos de validación. Si se compara este proceso de aciertos con un proceso *camino aleatorio*, es esperable que el modelo tenga una probabilidad de acierto al menos superior a 0.5; es decir superior a lanzar diariamente una moneda para definir si el papel va a subir o bajar su precio.

La validación cruzada con diferentes valores de tamaño de las medias móviles para las variables explicativas arrojó que a medida que aumenta el tamaño en días de las medias móviles, disminuye la eficiencia en la predicción. Para una ventana de **k=3 días** la suma de diferencias positivas y negativas con respecto a 0.5, es mayor y la cantidad de predicciones que se encuentran por debajo de la predicción 'camino aleatorio' son 2; mientras que para el resto de los tamaños la suma siempre es menor y decreciente a medida que k aumenta. En este sentido, es que se selecciona como opción más eficiente es k=3, siendo sólo en 2 de las 16 especies la predicción peor que un proceso aleatorio. En 3 de las restantes su eficiencia es muy cercana al 50% y en los 11 restantes, la performance es superior al 52.3%. Llegando a un máximo de 54.02% en el caso de Banco Galicia.

Tabla (b)

Especie	k=1	k=3	k=5	k=10
Aciertos para ALUA	55.01%	53.88%	53.74%	53.74%
Aciertos para APBR	57.12%	53.31%	54.02%	55.15%
Aciertos para BMA	50.63%	52.47%	52.47%	52.33%
Aciertos para COME	47.95%	50.78%	50.07%	46.54%
Aciertos para EDN	54.16%	53.60%	54.02%	54.16%
Aciertos para FRAN	51.62%	51.34%	51.62%	50.07%
Aciertos para GGAL	52.05%	54.02%	52.19%	52.19%
Aciertos para METR	50.78%	50.49%	50.49%	50.78%
Aciertos para MIRG	47.39%	47.81%	48.10%	47.95%
Aciertos para PAMP	53.17%	53.60%	53.31%	53.03%
Aciertos para TGNO4	54.44%	53.88%	53.88%	54.30%
Aciertos para TGSU2	53.17%	53.03%	53.17%	53.03%
Aciertos para TRAN	53.31%	52.89%	52.19%	52.33%
Aciertos para TS	53.03%	53.88%	52.75%	53.31%
Aciertos para TXAR	52.47%	52.89%	51.62%	51.34%
Aciertos para YPFD	49.93%	49.51%	51.20%	50.21%
Sobre 0.5 probabilidad	0.362	0.374	0.348	0.305
Cant. bajo 0.5	3	2	1	2

4.2. Vector de señales de compra/venta

El eje central del modelo es el vector de señales que arroja diariamente. Este se muestra en la Tabla (c) y es a partir del cual la estrategia financiera determinará la consiguiente acción de compra o venta de especies dentro del portafolio para el día siguiente. A continuación, se muestra como ejemplo una pantalla de la decisión recomendada por el modelo SMV.

Tabla (c)

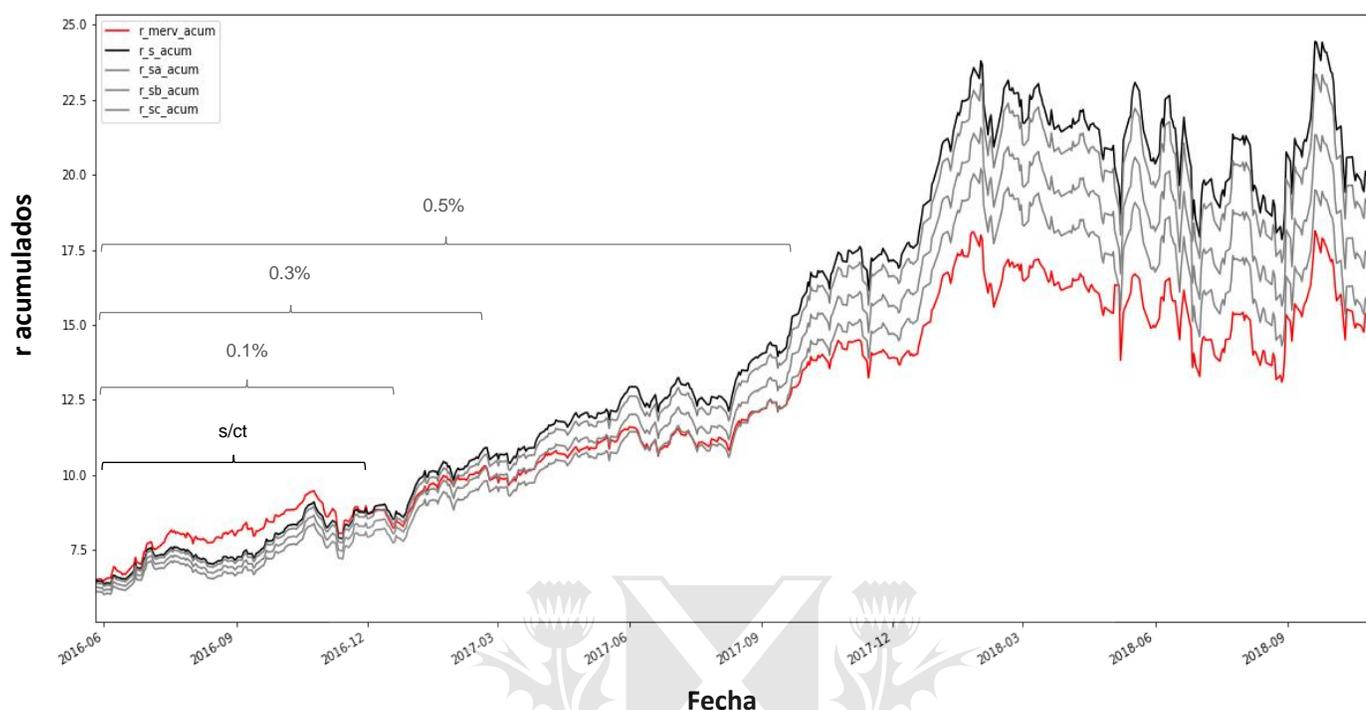
Acción de compra/venta recomendada para el día:	
2632	2 0 1 8 - 0 6 - 2 8
-----	-----
AGRO	compra
ALUA	venta
APBR	venta
BMA	venta
COME	compra
CRES	venta
EDN	compra
FRAN	venta
GGAL	venta
HARG	compra
METR	compra
MIRG	compra
PAMP	compra
TECO2	venta
TGNO4	compra
TGSU2	compra
TRAN	compra
TS	compra
TXAR	compra
YFPD	compra

4.3. Comparación contra el índice Merval 25

La estrategia propuesta en puntos anteriores implica la incursión en costos de transacción. Sin perjuicio de esto, se propone evaluar la estrategia con una comparable y con distintos niveles de comisión vigentes hoy en la Argentina. En ese caso, el portafolio de referencia es simplemente el índice Merval 25.

El armado del resultado diario y sus respectivos retornos se encuentra detallado en la Figura (I), siendo la línea roja la serie de retornos acumulados para el Merval 25 y la línea negra la serie de retornos acumulados de la estrategia SMV sin considerar costos de transacción. Las líneas grises corresponden a diferentes escalas de costos de transacción para compra/venta de acciones: 0.1%, 0.3% y 0.5%, respectivamente.

Figura (I)



Al mismo tiempo, se observa que los retornos del portafolio de estrategia son superiores a los retornos de Merval para todo el período, con excepción del periodo inicial: desde fines de 2016 en la estrategia sin costos de transacción hasta octubre de 2017 en el caso de costos de 0.5%, los retornos acumulados se mantienen por debajo de los del índice de referencia. Esto es, la estrategia demora en el mejor escenario un trimestre en superar en retornos acumulados al MERVAL 25.

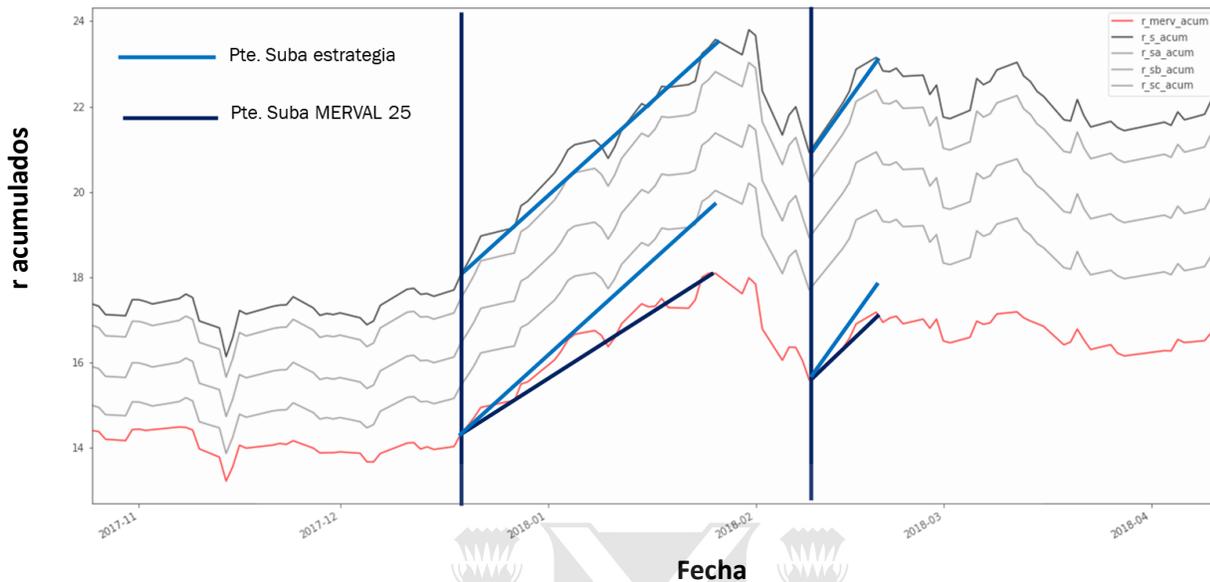
En cuanto a la forma del gráfico, puede verse en la Figura (m) que la estrategia aprovecha mejor los *momentum* positivos, cuando el índice de comparación realiza una suba, los retornos del portafolio estrategia exageran dicha suba despegándose con mayores retornos respecto del Merval, es fácil verlo con la diferencia de pendientes de las subas. Esto sucede puntualmente en las subas de fines de 2016, cuando como un punto de inflexión, los retornos de la estrategia sobrepasan a los del MERVAL. La explicación a esto se encuentra en la eficiencia de la predicción del modelo, el cual, es significativamente más eficiente en la predicción de las subas, pero no así en las caídas. En términos globales²⁵, el modelo logra predecir el 90.28% de las subidas, pero solo el 11.24% de las caídas.

Tabla (d)

Aciertos en caídas	↓	11.24%
Aciertos en subidas	↑	90.28%
Aciertos totales	→	52.34%

²⁵ Ver ANEXO I para los aciertos de subas y caídas por especie.

Figura (m)



Aun cuando la performance de la estrategia es superadora de la referencia, es preciso destacar el efecto de los costos de transacción en la performance de la estrategia, ya que con valores de 0.5% -vigentes hoy en el mercado argentino- esta resulta deficitaria hasta pasado octubre de 2017. Es decir, en un período superior cercano a un año desde el inicio de la estrategia diariamente pierde en comparación con el índice de referencia. Sin perjuicio de esto, la Tabla (d) muestra en cuanto supera en términos de retornos la estrategia a final del periodo de valuación; noviembre 2018. Tal como allí se observa, la estrategia que deriva del modelo de vectores de soporte (SMV) es considerablemente sensible al aumento de los costos de transacción; siendo en un caso de 0.5% sólo un 4.1% superior a la rentabilidad del índice de referencia en considerando el periodo de valuación.

Tabla (e)

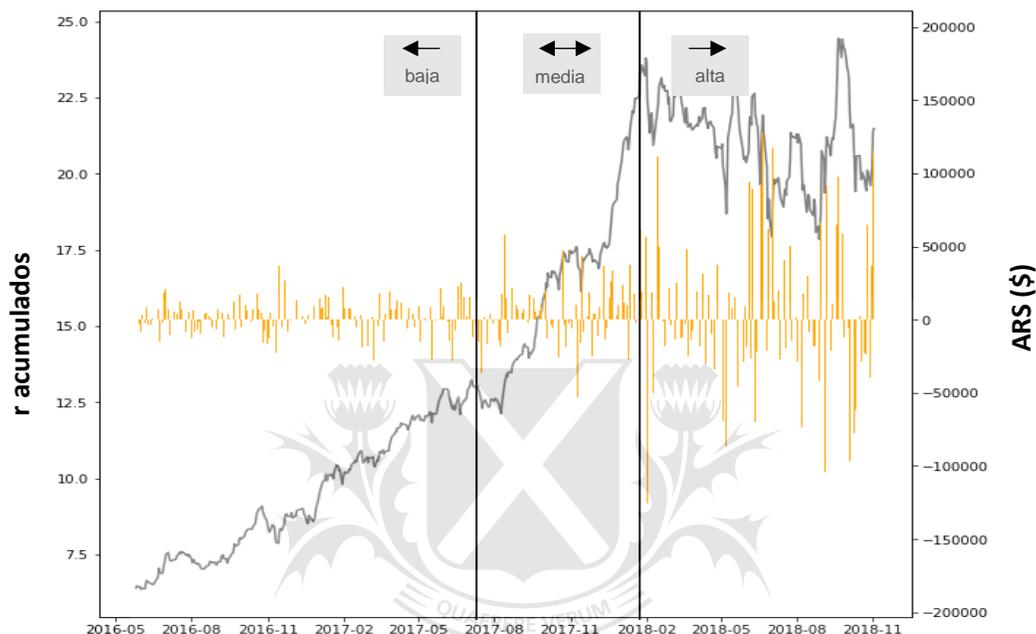
Tipo	% sobre Merval 25
Sin costo transacción	48.4%
Comisión 0.1%	38.7%
Comisión 0.3%	20.5%
Comisión 0.5%	4.1%

Adicionalmente, se observa que la volatilidad del portafolio de estrategia aumenta significativamente a partir de mediados de 2017. Siendo esta mayor a medida que se aleja de la fecha de inicio de aplicación del algoritmo dentro del conjunto de datos de valuación. En la Figura (i) se muestra, para el caso de la estrategia sin costos de transacción, la curva de retornos acumulados y las barras amarillas refieren a las ganancias/pérdidas diarias.

Si bien, hacia el final del periodo de valuación la curva de retornos acumulados se encuentra en su punto más alejado del índice de referencia. La misma, es contemporánea

con un aumento significativo de la volatilidad, gráficamente se observa en el tamaño de las barras hacia el final del periodo en comparación con el inicio del periodo. En términos de definir esta estrategia financiera en un paradigma de rentabilidad-riesgo, es preciso aclarar que el aumento de la rentabilidad se da juntamente con un aumento considerable de la volatilidad y por consiguiente su riesgo.

Figura (n)



En esta línea, si se calculan los desvíos estándar de los retornos para distintos periodos desde la fecha de corte del conjunto de valuación, se observa un aumento significativo de la misma a media que se toman horizontes de predicción más largos. En la Tabla (e), se muestran las volatilidades para distintos periodos de tiempo desde el periodo de corte. Hasta 270 días después, la volatilidad de los retornos de la estrategia se mantiene en niveles inferiores a los retornos del índice de referencia. No obstante, a partir del día 360, comienza a crecer exponencialmente hasta alcanzar un desvío estándar casi 60% más elevado que el del índice de referencia.

Tabla (f)

Días	Volatilidad		
	Estregetia S.C	Merval 25	Dif
Días 0 a 90	0.18	0.20	-10.7%
Días 90 a 180	0.49	0.58	-15.7%
Días 180 a 270	0.57	0.89	-36.3%
Días 270 a 360	1.20	1.26	-5.1%
Días 360 a 450	2.08	1.74	19.7%
Días 450 a 540	2.97	2.22	33.6%
Días 540 a 630	4.83	3.23	49.4%
Días 630 a 709	5.61	3.58	56.6%

4.4. Frecuencia de los datos y costos de transacción

Tal como se detalló anteriormente, los costos de transacción afectan negativamente los retornos de la estrategia basada en las señales del algoritmo SMV. Como alternativa y para reducción de dichos costos se realizaron simulaciones con frecuencias semanales y mensuales de los datos. Aún cuando el siguiente análisis sirve a los fines de analizar el impacto de las comisiones en la estrategia, es preciso aclarar que la menor cantidad de observaciones de entrenamiento fue en detrimento de la eficiencia de la predicción. Encontrando porcentajes de aciertos menores que la estrategia diaria con el uso de datos mensuales y semanales.

4.4.1. Frecuencia mensual

En el caso de la simulación con datos mensuales de precios de cierre, la curva de retornos acumulados se despega positivamente desde el índice de referencia en mayor medida si se lo compara con la estrategia diaria. La fecha de separación entre conjunto de datos de entrenamiento y de validación es en este caso, el 01 de diciembre de 2015. Esto deja para la validación sólo 35 observaciones de tipo mensual para cada especie y 107 observaciones de entrenamiento. Es preciso destacar, que el periodo de validación solo incluye 35 puntos de predicción en comparación con los más de 700 del algoritmo en base diario. La eficiencia de predicción logra apenas sobrepasar el 50% de probabilidad de acierto, con un 51.8%²⁶.

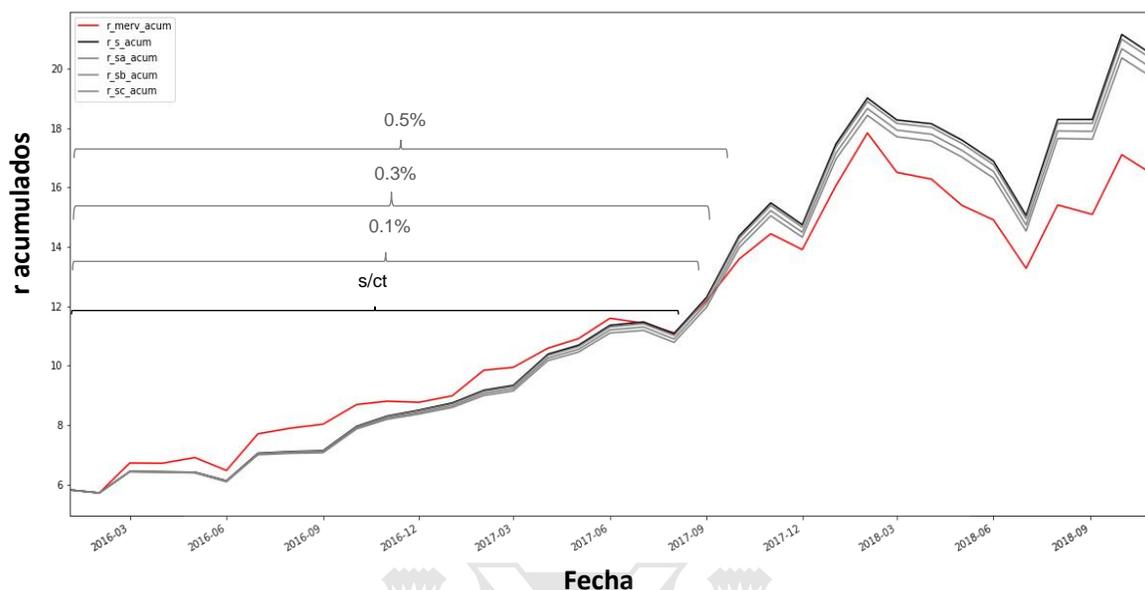
Tabla (g)

Aciertos en caídas	↓	37.04%
Aciertos en subidas	↑	61.05%
Aciertos totales	→	51.79%

Sin perjuicio de la robustez de la predicción, es posible analizar en este escenario los retornos con la estrategia mensual y su interacción con los costos de transacción. Tal como se esperaba, dada la menor frecuencia de compra/venta, los retornos en esta estrategia son superiores al índice, aunque continúa una brecha negativa en el inicio del periodo de validación; la misma se prolonga hacia principios de octubre de 2017. En la Figura (ñ) se observa también, el menor impacto en la curva de retornos de los costos de transacción en comparación con la estrategia diaria, siendo esta menos sensible a aumentos en dichas comisiones.

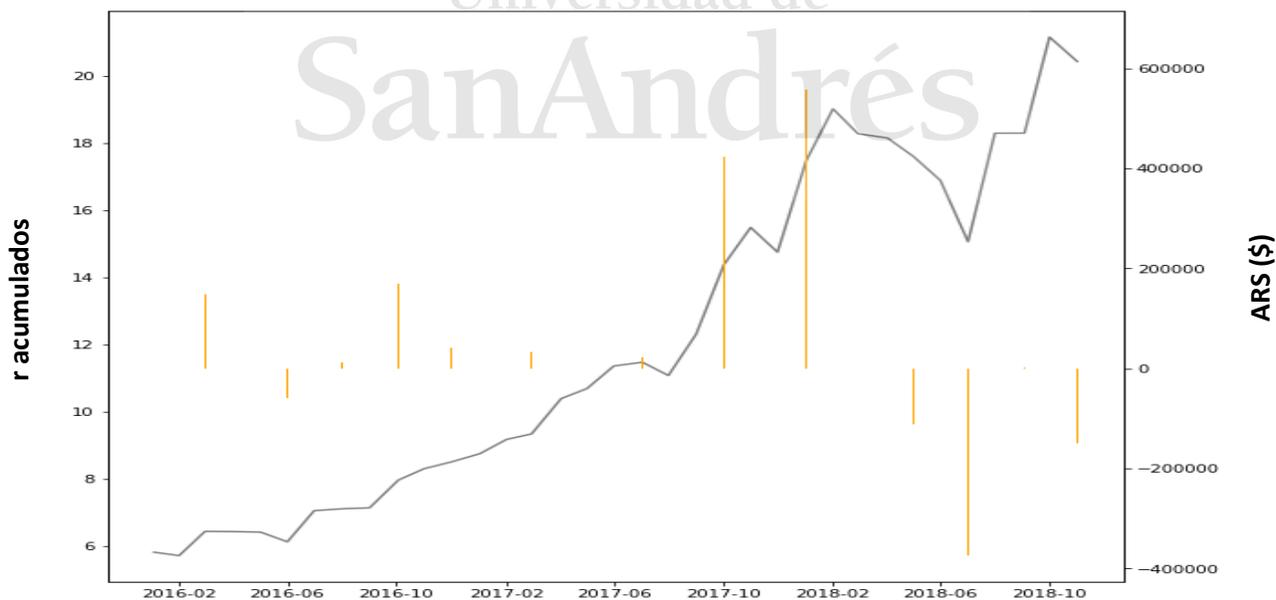
²⁶ Ver ANEXO II para los aciertos mensuales de subas y caídas por especie.

Figura (ñ) – CURVAS MENSUAL



Si se observa la volatilidad, se detectan menores desvíos estándar comparados con los del índice de referencia. En la Figura (o) se muestran las pérdidas y ganancias mensuales de la estrategia en contraposición con la curva de retornos acumulados.

Figura (o)



Luego en la Tabla (h), la volatilidad para distintos periodos de tiempo, con intervalos aproximados de 90 ruedas, es menor a la observada en el caso de la estrategia diaria. Llegando a un máximo de 25% mayor volatilidad que el índice de referencia.

Tabla (h)

Días	Volatilidad		
	Estregetia S.C	Merval 25	Dif
Mes 0 a 4	0.39	0.55	-29.7%
Mes 4 a 8	0.51	0.78	-34.9%
Mes 8 a 12	0.94	1.11	-15.9%
Mes 12 a 16	1.41	1.50	-5.8%
Mes 16 a 20	1.95	1.90	2.5%
Mes 20 a 24	2.92	2.57	13.9%
Mes 24 a 28	4.19	3.51	19.4%
Mes 28 a 32	4.49	3.59	25.0%
Mes 32 a 35	4.37	3.56	23.0%

4.4.2. Frecuencia semanal

En cuanto a la serie semanal, el periodo de validación en este caso dejó 151 observaciones semanales desde diciembre 2015 hasta noviembre 2018. En este caso, la predicción empeora en términos de eficiencia y solo por un 0.9% de probabilidad se supera al escenario de camino aleatorio, siendo el porcentaje total de aciertos de un 50.9%²⁷.

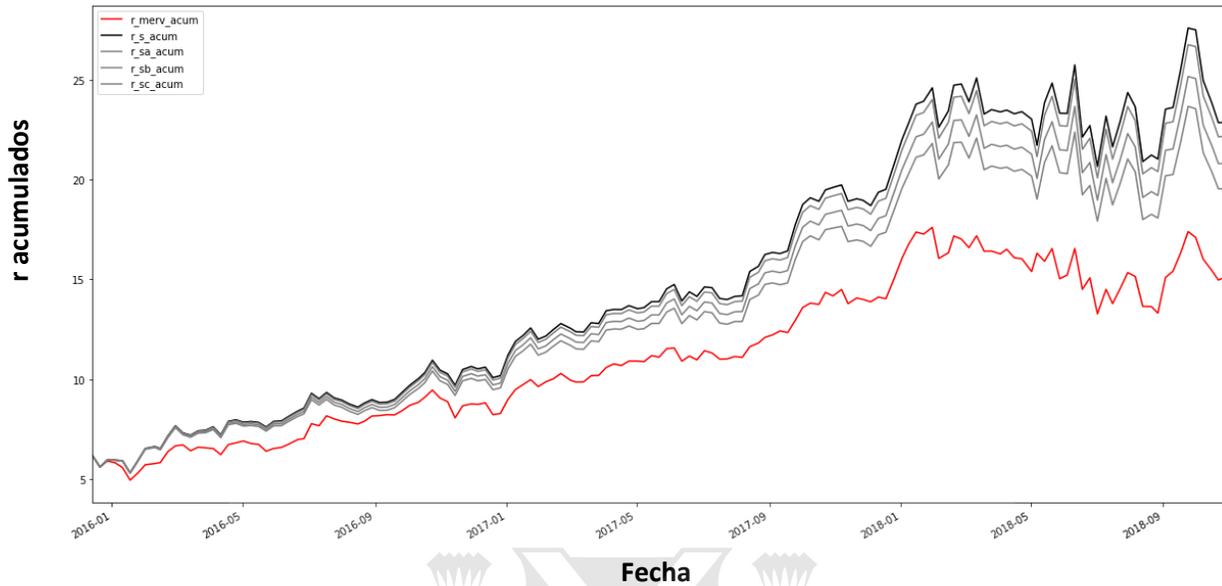
Tabla (i)

Aciertos en caídas	↓	34.05%
Aciertos en subidas	↑	65.31%
Aciertos totales	→	50.91%

En la Figura (p), la línea de retornos acumulados de la estrategia supera al índice de referencia, en todo el periodo de validación. Nuevamente, la incidencia de las comisiones disminuye significativamente con respecto a la estrategia diaria.

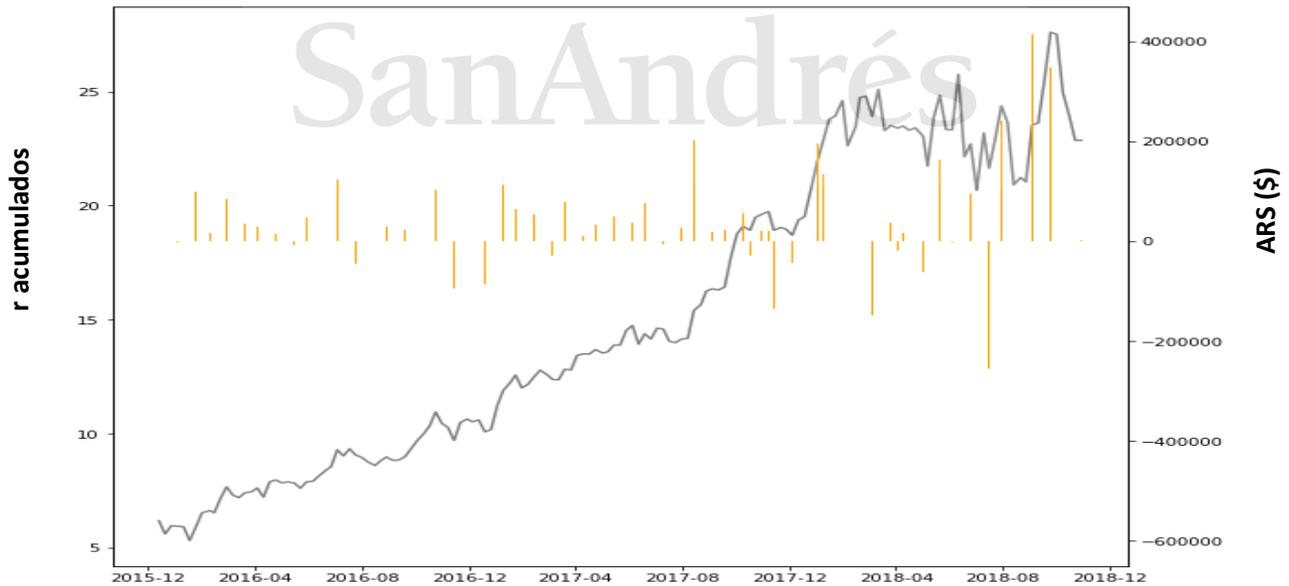
²⁷ Ver ANEXO III para los aciertos semanales de subas y caídas por especie.

Figura (p) – CURVAS SEMANAL



En cuanto a la volatilidad, en la Figura (q) el último tramo del periodo de validación muestra como en las demás estrategias mayor volatilidad de pérdidas y ganancias. Cuestión que se verifica en la Tabla (j), en la cual la volatilidad para todo el periodo de validación es mayor a la presente en el índice de referencia.

Figura (q)



En este caso particular, los retornos de la estrategia SMV presentan una volatilidad particularmente elevada a lo largo del periodo de predicción llegando, en

su punto máximo, a sobrepasar el desvío estándar del índice de referencia en más de un 70%. Esta cuestión es de vital importancia a la hora de evaluar los rendimientos de la misma en un paradigma riesgo/volatilidad.

Tabla (j)

Días	Volatilidad		
	Estretega S.C	Merval 25	Dif
Semana 0 a 18	0.755	0.510	48.0%
Semana 18 a 36	1.105	0.798	38.5%
Semana 36 a 54	1.493	1.164	28.3%
Semana 54 a 72	2.271	1.578	44.0%
Semana 72 a 90	2.897	1.949	48.6%
Semana 90 a 108	4.184	2.674	56.5%
Semana 108 a 126	5.690	3.527	61.3%
Semana 126 a 144	6.198	3.612	71.6%
Semana 144 a 151	6.001	3.619	65.8%

4.4.3. Costos de transacción para diferentes frecuencias

Los costos de transacción son una pieza fundamental de esta estrategia de compra/venta y el estudio de simulaciones a diferentes frecuencias permite estimar la sensibilidad de la misma a distintos niveles de comisión.

En las Tablas (k.1, k.2 y k.3) se muestran la rentabilidad de cada portafolio simulado (base diaria, semanal y mensual) y la rentabilidad del índice de referencia a lo largo del periodo de valuación de la estrategia, esto es diciembre 2016 hasta noviembre 2018. Las fechas exactas para la toma de retornos del índice de referencia y de los portafolios estrategia son las siguientes:

- Inicio 15/12/2015 hasta 02/11/2018.

En la Tabla (k.1) específicamente, se observa que, en el caso de un escenario sin costos de transacción, el portafolio con **estrategia diaria** supera la rentabilidad del índice de referencia en un 48.4%, con 0.1% de comisión un 38.7%, con 0.3% de comisión un 20.5% y con 0.5% de comisión un 4.1%.

Tabla (k.1) - DIARIA		
Portafolios	Retornos	sobre-retorno
Indice de referencia	168.0%	
Porfolio sin costos de transacción	249.3%	48.4%
Porfolio con 0.1% de CT	232.9%	38.7%
Porfolio con 0.3% de CT	202.5%	20.5%
Porfolio con 0.5% de CT	174.8%	4.1%
<i>Inicio 15/12/2015 hasta 02/11/2018</i>		

Luego, en la Tabla (k.2) específicamente, se observa que, en el caso de un escenario sin costos de transacción, el portafolio con **estrategia semanal** supera la rentabilidad del índice de referencia en un 83.9%, con 0.1% de comisión un 76.3%, con 0.3% de comisión un 61.9% y con 0.5% de comisión un 48.3%.

Tabla (k.2) - SEMANAL		
Portafolios	Retornos	sobre-retorno
Indice de referencia	168.0%	
Porfolio sin costos de transacción	308.9%	83.9%
Porfolio con 0.1% de CT	296.2%	76.3%
Porfolio con 0.3% de CT	271.9%	61.9%
Porfolio con 0.5% de CT	249.1%	48.3%
<i>Inicio 15/12/2015 hasta 02/11/2018</i>		

Finalmente, en la Tabla (k.3) específicamente, se observa que, en el caso de un escenario sin costos de transacción, el portafolio con **estrategia mensual** supera la rentabilidad del índice de referencia en un 29.6%, con 0.1% de comisión un 28.3%, con 0.3% de comisión un 25.5% y con 0.5% de comisión un 22.8%.

Tabla (k.3) - MENSUAL		
Portafolios	Retornos	sobre-retorno
Indice de referencia	168.0%	
Porfolio sin costos de transacción	217.8%	29.6%
Porfolio con 0.1% de CT	215.4%	28.3%
Porfolio con 0.3% de CT	210.9%	25.5%
Porfolio con 0.5% de CT	206.4%	22.8%
<i>Inicio 15/12/2015 hasta 02/11/2018</i>		

4.4.4. Evaluación de portfolios: medida de rentabilidad/riesgo

En línea como se dijo anteriormente, un componente importante de las estrategias simuladas es su alta volatilidad con respecto a la presente en el índice de referencia. Para evaluar la conveniencia de una u otra estrategia se calculó la ratio de Sharpe cuya formulación se detalla a continuación:

$$\bullet \text{ Sharpe ratio} = \frac{(r_p - r_f)}{\sigma_p}$$

Donde r_p es el retorno del portfolio, r_f es la tasa libre de riesgo de referencia y σ_p la volatilidad de los retornos del portfolio por sobre la r_f .

En la Tabla (I)²⁸, se muestran para las estrategias en base diaria, semanal y mensual ambas medidas. En todos los casos, fueran calculadas para el caso de los retornos sin costos de transacción, dado que las medidas de volatilidad se mantienen invariables ante aumentos de los costos de transacción, incorporar los costos de transacción solo haría disminuir el numerador de ambos indicadores y por consiguiente la ratio. Ambas medidas confirman el exceso de retorno respecto al de referencia, aunque, en términos de Sharpe, no logra compensarse la alta volatilidad de los retornos del portfolio estrategia; siendo en todos los casos menor a 1. Cada punto adicional de volatilidad del portfolio reporta, en el mejor de los casos (mensual), un exceso de retorno del portfolio de 0,483 contra un Sharpe de referencia de 0.512.

San Andrés

Tabla (I)

	Sharpe
Portfolio de referencia	0.512
Portfolio en base diario	0.421
Portfolio en base Semanal	0.483
Portfolio en base mensual	0.450
<i>Retornos sin costos de transacción</i>	

²⁸ Las volatilidades fueron computadas para el mismo periodo comparable de referencia de los retornos, detallado en el punto 4.4.3.

5. COMENTARIOS FINALES

Los resultados de este trabajo confirman la posibilidad de encontrar una estrategia de compra y venta de acciones basada en un algoritmo SVM que supere un índice de referencia, en este caso el Merval 25. Tal como fue enunciado en la revisión bibliográfica, también se encontraron evidencias de que la técnica de aprendizaje automático de SVM obtiene resultados superiores a un proceso de *camino aleatorio* en la predicción de precios en series de tiempo financieras. Saahil et al (2015)²⁹ encuentra una performance similar de entre 55% y 60% utilizando un portafolio de 34 acciones tecnológicas de Estados Unidos, siendo esto posible también para tendencias de corto plazo inferiores a 270 ruedas. En este caso, la eficiencia global de predicción del portafolio de acciones de Merval elegidas superó el 52%.

En cuanto a si dicha eficiencia puede ser traducida o no en una estrategia financiera con retornos mayores al índice de referencia, también se encontraron retornos acumulados superiores a los esperados por el índice de referencia. Asimismo, el algoritmo sigue de manera efectiva el *momentum* de las subas del índice aun cuando no resulta tan claro para el caso de evitar las bajas de precios.

Sin perjuicio de esto, dos cuestiones merecen ser resaltadas del análisis de los resultados. En primer lugar, la sensibilidad de esta estrategia a los costos de transacción. Siendo que, valores que hoy se encuentran vigentes en el mercado, acortan los retornos de la estrategia diaria con respecto al índice de referencia; dejando un margen estrecho, en el caso de las comisiones más altas, para el pago de otros derechos de mercado que también serían exigibles. Estrategias de menor frecuencia, semanales y mensuales fueron testeadas y se evidenció menor sensibilidad a los costos de transacción y mayores retornos.

En la misma línea, la siguiente limitación es el aumento de la volatilidad a medida que se alarga el horizonte de predicción. Si bien en todos los casos los rendimientos superan al índice de referencia en el final del periodo, la volatilidad es hasta un 60% mayor a la de referencia en el caso de la diaria y más de un 70% en el caso de la semanal.

Finalmente, la evaluación de las diferentes estrategias en un paradigma de rentabilidad/riesgo, arroja resultados cercanos a 0.5 de acuerdo con la ratio de Sharpe. En estos términos, cada punto de volatilidad implica en el mejor de los casos 0.483 puntos de retorno, no logrando compensar la mayor volatilidad que implica seguir la estrategia de señales de precios de SMV.

²⁹ Madge, Saahil, and S. Bhatt. "Predicting Stock Price Direction using Support Vector Machines." *Independent Work Report Spring* (2015).

6. BIBLIOGRAFÍA

- i. Abu-Mostafa, Yaser S., and Amir F. Atiya. "Introduction to financial forecasting." *Applied Intelligence* 6.3 (1996): 205-213.
- ii. Deboeck, Guido. *Trading on the edge: neural, genetic, and fuzzy systems for chaotic financial markets*. Vol. 39. John Wiley & Sons, 1994.
- iii. Fama, Eugene F. "Efficient Capital Markets: A Review of Theory and Empirical Work." *The Journal of Finance*, vol. 25, no. 2, 1970, pp. 383–417. JSTOR, JSTOR, www.jstor.org/stable/2325486.
- iv. Fletcher, T. S. B. *Machine Learning for financial market prediction*. Diss. UCL (University College London), 2012.
- v. Hamid, Shaikh A., and Abraham Habib. "Can neural networks learn the Black-Scholes model? A simplified approach." (2005).
- vi. Huang, Wei, Yoshiteru Nakamori, and Shou-Yang Wang. "Forecasting stock market movement direction with support vector machine." *Computers & Operations Research* 32.10 (2005): 2513-2522.
- vii. Kim, E. (2013). Everything you wanted to know about the kernel trick. URI: http://www.eric-kim.net/eric-kim-net/posts/1/kernel_trick.html.
- viii. Kim, Kyoung-jae. "Financial time series forecasting using support vector machines." *Neurocomputing* 55.1-2 (2003): 307-319.
- ix. Lo, Andrew W., Harry Mamaysky, and Jiang Wang. "Foundations of technical analysis: Computational algorithms, statistical inference, and empirical implementation." *The journal of finance* 55.4 (2000): 1705-1765.
- x. Mukherjee, Sayan, Edgar Osuna, and Federico Girosi. "Nonlinear prediction of chaotic time series using support vector machines." *Neural Networks for Signal Processing [1997] VII. Proceedings of the 1997 IEEE Workshop*. IEEE, 1997.
- xi. Müller, K-R., et al. "Predicting time series with support vector machines." *International Conference on Artificial Neural Networks*. Springer, Berlin, Heidelberg, 1997.
- xii. Rosillo, Rafael, Javier Giner, and David De la Fuente. "Stock market simulation using support vector machines." *Journal of Forecasting* 33.6 (2014): 488-500.
- xiii. Sethi, Mininder, Philip Treleaven, and Sebastian Del Bano Rollin. "Beating the S&P 500 index—A successful neural network approach." *Neural Networks (IJCNN), 2014 International Joint Conference on*. IEEE, 2014.
- xiv. Tay, Francis EH, and L. J. Cao. "Modified support vector machines in financial time series forecasting." *Neurocomputing* 48.1-4 (2002): 847-861.
- xv. Tay, Francis EH, and Lijuan Cao. "Application of support vector machines in financial time series forecasting." *omega* 29.4 (2001): 309-317.
- xvi. Vapnik, V. *Statistical learning theory*. New York: Wiley (1998).
- xvii. Yao, Jingtao, and Chew Lim Tan. "A case study on using neural networks to perform technical forecasting of forex." *Neurocomputing* 34.1-4 (2000): 79-98.

Sitios Web

- i. *scikit-learn Aprendizaje automático in Python* - <http://scikit-learn.org/>
- ii. *NumPy* - <http://www.numpy.org/>
- iii. *Matplotlib Python 2D plotting* - <https://matplotlib.org/>
- iv. *Pandas Python Data Analysis Library* - <https://pandas.pydata.org/>

7. ANEXO I

Predicciones diarias de subidas/caídas por especie.

ALUA	Caídas	↓	7.55%
	Subidas	↑	94.44%
	Total	→	53.88%
APBR	Caídas	↓	13.50%
	Subidas	↑	87.21%
	Total	→	53.31%
BMA	Caídas	↓	15.82%
	Subidas	↑	85.29%
	Total	→	52.47%
COME	Caídas	↓	67.32%
	Subidas	↑	34.18%
	Total	→	50.78%
EDN	Caídas	↓	3.07%
	Subidas	↑	96.61%
	Total	→	53.60%
FRAN	Caídas	↓	4.84%
	Subidas	↑	96.93%
	Total	→	51.34%
GGAL	Caídas	↓	13.53%
	Subidas	↑	91.33%
	Total	→	54.02%
METR	Caídas	↓	0.00%
	Subidas	↑	100.00%
	Total	→	50.49%
MIRG	Caídas	↓	0.00%
	Subidas	↑	100.00%
	Total	→	47.81%
PAMP	Caídas	↓	0.30%
	Subidas	↑	100.00%
	Total	→	53.60%
TGNO4	Caídas	↓	0.31%
	Subidas	↑	99.74%
	Total	→	53.88%
TGSU2	Caídas	↓	0.00%
	Subidas	↑	100.00%
	Total	→	53.03%
TRAN	Caídas	↓	8.50%
	Subidas	↑	94.02%
	Total	→	52.89%
TS	Caídas	↓	15.96%
	Subidas	↑	87.27%
	Total	→	53.88%
TXAR	Caídas	↓	4.93%
	Subidas	↑	98.35%
	Total	→	52.89%
YPDF	Caídas	↓	21.81%
	Subidas	↑	76.97%
	Total	→	49.51%

8. ANEXO II

Predicciones mensuales de subidas/caídas por especie.

ALUA	Caídas	↓	57.14%
	Subidas	↑	66.67%
	Total	→	62.86%
APBR	Caídas	↓	9.09%
	Subidas	↑	87.50%
	Total	→	62.86%
BMA	Caídas	↓	6.67%
	Subidas	↑	95.00%
	Total	→	57.14%
COME	Caídas	↓	57.14%
	Subidas	↑	38.10%
	Total	→	45.71%
EDN	Caídas	↓	83.33%
	Subidas	↑	39.13%
	Total	→	54.29%
FRAN	Caídas	↓	5.88%
	Subidas	↑	94.44%
	Total	→	51.43%
GGAL	Caídas	↓	0.00%
	Subidas	↑	86.36%
	Total	→	54.29%
METR	Caídas	↓	68.75%
	Subidas	↑	26.32%
	Total	→	45.71%
MIRG	Caídas	↓	0.00%
	Subidas	↑	100.00%
	Total	→	60.00%
PAMP	Caídas	↓	80.00%
	Subidas	↑	30.00%
	Total	→	51.43%
TGNO4	Caídas	↓	16.67%
	Subidas	↑	73.91%
	Total	→	54.29%
TGSU2	Caídas	↓	30.00%
	Subidas	↑	60.00%
	Total	→	51.43%
TRAN	Caídas	↓	75.00%
	Subidas	↑	21.74%
	Total	→	40.00%
TS	Caídas	↓	72.73%
	Subidas	↑	29.17%
	Total	→	42.86%
TXAR	Caídas	↓	25.00%
	Subidas	↑	31.58%
	Total	→	28.57%
YFPD	Caídas	↓	14.29%
	Subidas	↑	100.00%
	Total	→	65.71%

9. ANEXO III

Predicciones semanales de subidas/caídas por especie.

ALUA	Caídas	↓	36.00%
	Subidas	↑	71.05%
	Total	→	53.64%
APBR	Caídas	↓	27.27%
	Subidas	↑	55.29%
	Total	→	43.05%
BMA	Caídas	↓	1.43%
	Subidas	↑	93.83%
	Total	→	50.99%
COME	Caídas	↓	90.54%
	Subidas	↑	15.58%
	Total	→	52.32%
EDN	Caídas	↓	63.24%
	Subidas	↑	43.37%
	Total	→	52.32%
FRAN	Caídas	↓	24.05%
	Subidas	↑	79.17%
	Total	→	50.33%
GGAL	Caídas	↓	0.00%
	Subidas	↑	100.00%
	Total	→	54.30%
METR	Caídas	↓	40.91%
	Subidas	↑	57.65%
	Total	→	50.33%
MIRG	Caídas	↓	0.00%
	Subidas	↑	100.00%
	Total	→	50.99%
PAMP	Caídas	↓	16.13%
	Subidas	↑	77.53%
	Total	→	52.32%
TGNO4	Caídas	↓	67.19%
	Subidas	↑	26.44%
	Total	→	43.71%
TGSU2	Caídas	↓	24.29%
	Subidas	↑	81.48%
	Total	→	54.97%
TRAN	Caídas	↓	65.57%
	Subidas	↑	42.22%
	Total	→	51.66%
TS	Caídas	↓	27.27%
	Subidas	↑	68.24%
	Total	→	50.33%
TXAR	Caídas	↓	30.56%
	Subidas	↑	74.68%
	Total	→	53.64%
YFPD	Caídas	↓	35.06%
	Subidas	↑	64.86%
	Total	→	49.67%