

Tesis de Maestría

**Tendencias Recientes en el Pronóstico de Series de Tempo Financieras usando
Máquinas de Vectores de Soporte**

Johana Alexandra Jaramillo, I.A, Esp. I.F.



Director

Juan David Velásquez Henao, MSc, PhD

Universidad Nacional de Colombia
Facultad de Minas
Área Curricular de Ingeniería Administrativa e Ingeniería Industrial
Programa de Maestría en Ingeniería Administrativa
Junio de 2015

Agradecimientos

A mi director de tesis Juan David Velásquez por apoyarme y tomarme de la mano en este proceso, a John Wilian Branch por creer en mí y darme la oportunidad de culminar mi maestría, A Sandra Uribe por darme un lugar en su laboratorio, a mis amigos por ser mi familia y darme fuerza y a mi hijo Miguel Ángel, sin él este sueño no sería realidad.

RESUMEN

El pronóstico de las series de tiempo financieras es un área de trabajo intensiva para investigadores y profesionales. En este estudio, analizamos 59 artículos y discutimos sobre el progreso en el análisis de series de tiempo financieras usando máquinas de vectores de soporte. Las principales conclusiones a las que llegamos son: (a) el pronóstico se hace con datos de frecuencia diaria y los estudios con otras frecuencias de tiempo son escasos; (b) la mayoría de los artículos están enfocados en mejorar el proceso de estimación de los parámetros o en el tratamiento previo de las series de tiempo; (c) la mayor parte de los artículos se concentran en el pronóstico de un índice financiero del mercado; (d) los casos experimentales están dispersos, lo que no hace posible comparar entre diferentes estudios.

Palabras Clave: procesamiento de datos financieros; series de tiempo financieras; Redes neuronales; vectores de soporte para regresión; optimización heurística

ABSTRACT

Forecasting of financial time series is an intensive working area for researchers and practitioners. In this study, we analyze 59 articles and discuss the progress in financial time series analysis using support vector machines. Our main conclusions are: (a) forecasting is doing in a daily basis and studies in other time scales are scarce; (b) most of works are devoted to improve the parameter estimation process or to preprocessing the time series; (c) most of the work is concerned to forecast market financial index; (d) experimental cases are disperse and it is no possible to compare between different studies.

Keywords— Financial data processing; financial time series; neural networks; support vector regression; heuristic optimization.

CONTENIDO

LISTA DE TABLAS	XI
LISTA DE FIGURAS	XIII
1 INTRODUCCIÓN	1
2 INTRODUCCIÓN AL PRONÓSTICO DE SERIES DE TIEMPO USANDO SVMS .	3
3 METODOLOGÍA	5
4 RESULTADOS OBTENIDOS	7
5 DISCUSIÓN	13
5.1 ¿Cuáles son las arquitecturas (funciones de núcleo) de SVM para las que se han reportado resultados en el pronóstico de series de tiempo financieras?.....	13
5.2 ¿Qué metodologías se han usado para estimar los parámetros de SVM?	14
5.3 ¿Cuáles son los tipos de series de tiempo financieras que se han pronosticado?	14
5.4 ¿Qué periodicidad reportan estas series de tiempo?	17
5.5 ¿Qué tipos de transformaciones se aplicaron a las series de tiempo?	18
5.6 ¿Cuáles fueron los modelos utilizados para comparar la capacidad predictiva de SVM? 19	
5.7 ¿Cuáles medidas de ajuste han sido utilizadas para medir la precisión de los modelos?	24
5.8 ¿Cuáles son las principales conclusiones a las que llegaron los investigadores en la literatura revisada?	25
6 CONCLUSIONES	29
REFERENCIAS	31

LISTA DE TABLAS

Tabla 1. Principales Funciones Kernel.....	4
Tabla 2. Principales Funciones Kernel.....	8
Tabla 3. Artículos y número de citasiones	10
Tabla 4. Funciones de núcleo utilizadas.....	13
Tabla 5. Tipos de Series Financieras Pronosticadas.....	14
Tabla 6. Nombre de las series de tiempo financieras pronosticadas y su clasificación.....	15
Tabla 7. Principales transformación de las series.....	18
Tabla 8. Modelos de Comparación Predictiva de SVM	20
Tabla 9. Principales conclusiones reportadas en la literatura seleccionada.....	25

LISTA DE FIGURAS

Fig. 1 Cantidad de trabajos publicados por año.	7
Fig. 2 Principales palabras clave usadas en los artículos seleccionados.	8
Fig. 3 Autores con la mayor cantidad de artículos publicados.	9
Fig. 4 Total de artículos publicados por país de origen de las instituciones.	9
Fig. 5 Total de artículos publicados por filiación de los autores.	10

1 INTRODUCCIÓN

En esta revisión se analizan las principales contribuciones que se han realizado sobre el pronóstico de series de tiempo financieras usando máquinas de vectores de soporte (SVM, por su sigla en inglés). Tanto investigadores como profesionales han reconocido que el pronóstico es una tarea desafiante ya que los mercados financieros siguen dinámicas complejas, no lineales, caóticas, ruidosas y cambiantes en el tiempo [1] haciéndolos volátiles, no estacionarios, multifractales, de memoria larga, inestables y de alto riesgo [2] [3] [4] [5] [6]; los mercados son impactados por diferentes factores psicológicos, políticos y económicos que afectan la formación de diversas variables financieras [7]. Aunque la hipótesis de los mercados eficientes postula la imposibilidad de pronosticar las series de tiempo financieras, las experiencias reportadas en la literatura señalan lo contrario [8] [9] [10] [11] [12], de tal forma que muchas investigaciones están orientadas a obtener modelos que generen una ventaja competitiva en términos de su capacidad de pronóstico con el fin de obtener beneficios o evitar pérdidas [13]. Es claro que las técnicas más clásicas de pronóstico, tales como los modelos de Box-Jenkins, han sido ampliamente superadas por otras técnicas provenientes de la estadística, la física y el aprendizaje de máquinas, entre las que se incluyen las redes neuronales [14], los modelos híbridos [15], las técnicas neurodifusas [16], los sistemas expertos [17] y las máquinas de aprendizaje extremo [18]. En [19] y [20] se presenta un resumen de las principales metodologías basadas en inteligencia artificial.

Particularmente, las SVMs han recibido mucha atención en el pronóstico financiero debido a su alta capacidad de generalización y a que solo poseen un único mínimo global en la función de error usada para estimar sus parámetros óptimos [21] [22], lo que les da una clara ventaja sobre muchos otros modelos de redes neuronales artificiales [23]. Este tipo de red neuronal fue propuesta para la solución de problemas de clasificación por Vapnik y otros [22] [24] [25] [26] y se ha extendido a la solución de problemas de regresión [24] [27] y de pronóstico de series de tiempo en general [28] [29] [30] [31] [32] [33] debido a su alta capacidad de generalización [21] [34]. Su fundamentación teórica se basa en la teoría de aprendizaje estadístico, tal que se minimiza el límite superior del error de generalización (riesgo estructural) en vez de minimizar el error de ajuste del modelo a los datos de entrenamiento (que cuantifica únicamente el riesgo empírico) [21] [22]; de esta forma, el proceso de optimización permite determinar tanto los parámetros como la estructura óptima del modelo [35]. Otro aspecto fundamental de las SVMs es el uso de las funciones kernel, lo cual equivale a mapear una función no lineal definida en un espacio de baja dimensionalidad a una función lineal equivalente definida en un espacio de muchas dimensiones. En la literatura más relevante se concluye que la capacidad predictiva de las SVM es mejorada cuando sus parámetros son estimados usando técnicas de optimización basada en colonias de enjambres de partículas [13] [36] [37], de abejas [38] [39] o de hormigas [23]; su precisión puede mejorar al combinarlas con otros modelos [2], [40], [41]. Así mismo, hay estudios que reportan que las SVMs superan en precisión a los modelos autorregresivos

de medias móviles, [42], [43], las redes neuronales artificiales [13] [36] [43] y los sistemas adaptativos de inferencia neuro-difusos [38] [44].

Este trabajo resume la información existente más relevante sobre los estudios empíricos que evalúan la precisión de las SVMs en la predicción de series de tiempo financieras entre los años 2000 y 2014, con el fin de establecer los principales avances logrados en relación a la selección de la mejor arquitectura, los algoritmos de optimización, la minimización del error y la potencialidad de SVM en comparación con otros modelos de uso más difundido. Igualmente ayuda a clasificar, organizar y caracterizar las diferentes aproximaciones que se han usado en el problema en cuestión, así como también a integrar los hallazgos realizados en diferentes investigaciones. Este trabajo se focaliza en los documentos que pronostican series de tiempo financieras como son los precios de las acciones, los tipos de cambio, los precios de índices financieros y los índices de tasa de interés.

El objetivo de este trabajo es responder las siguientes preguntas de investigación:

- Q1. ¿Cuáles son las arquitecturas (funciones de núcleo) de SVM para las que se han reportado resultados en el pronóstico de series de tiempo financieras?
- Q2. ¿Qué metodologías se han usado para estimar los parámetros de SVM?
- Q3. ¿Cuáles son los tipos de series de tiempo financieras que se han pronosticado?
- Q4. ¿Qué periodicidad reportan estas series de tiempo?
- Q5. ¿Qué tipos de transformaciones se aplicaron a las series de tiempo?
- Q6. ¿Cuáles fueron los modelos alternativos utilizados para comparar la capacidad predictiva de las SVM?
- Q7. ¿Cuáles medidas de ajuste han sido utilizadas para medir la precisión de los modelos?
- Q8. ¿Cuáles son las principales conclusiones a las que llegaron los investigadores en la literatura revisada?

Las respuestas a las preguntas anteriores tienen un impacto positivo para: los investigadores del área de ingenierías interesados en el pronóstico de series de tiempo financieras y que amplíen sus conocimientos en modelación con herramientas novedosas y potentes; los investigadores del área de estadística que quieran complementar las metodologías econométricas existentes con nuevos modelos de pronóstico; y los diferentes participantes de los mercados de capitales que quieran aplicar modelos de pronósticos nuevos que disminuyan la incertidumbre en el riesgo de inversión.

Este documento está organizado de la siguiente forma: En el Capítulo 2 se presenta una corta introducción al uso de las SVMs en el pronóstico de series de tiempo financieras; en el Capítulo 3 se discute el protocolo de investigación utilizado; en el Capítulo 4 se presentan los resultados obtenidos; en el Capítulo 5 se responden las preguntas de investigación; y finalmente, en el Capítulo 6 se concluye.

2 INTRODUCCIÓN AL PRONÓSTICO DE SERIES DE TIEMPO USANDO SVMs

Una serie de tiempo (financiera) se define como un conjunto ordenada de observaciones P_1, \dots, P_T las cuales representan la evolución en el tiempo del precio de un activo financiero o físico, entre los que se incluyen las acciones, las tasas de interés, los índices financieros, diferentes *commodities* y las tasas de cambio. A partir de la hipótesis de mercados eficientes, los cambios en los precios son aleatorios ya que el precio actual contiene toda la información disponible hasta la fecha; esto es, se considera que siguen un paseo aleatorio. Es así entonces, como la serie de precios P_1, \dots, P_T es sustituida por sus rendimientos discretos:

$$R_t = \frac{P_t - P_{t-1}}{P_{t-1}}$$

o por sus rendimientos logarítmicos:

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right)$$

Sin pérdida de generalidad se considerará que variable z_t puede representar los rendimientos discretos o logarítmicos. Cuando se usan modelos de redes neuronales artificiales, los rendimientos pueden ser usados directamente ($y_t = z_t$), normalizados a un intervalo [10] [39] [44] [45] [46]:

$$y_t = \frac{z_t - \min(z_t)}{\max(z_t) - \min(z_t)}$$

o estandarizados:

$$y_t = \frac{z_t - \bar{z}_t}{\sigma_z}$$

donde \bar{z}_t y σ_z representa la media y la desviación estándar de la serie z_t [5] [10] [39] [47] [48] [49].

En el caso del pronóstico de series de tiempo con SVMs, se asume que el valor actual de la serie y_t es función de sus P valores pasados, tal que [39] [46] [50] [51]:

$$\hat{y}_t = f(\mathbf{x}_t, \mathbf{w}) = w_0 + \sum_{d=1}^N w_d \varphi(\mathbf{x}_t, \mathbf{x}_d)$$

donde $\mathbf{x}_t = [y_{t-1}, \dots, y_{t-p}]'$; N es la cantidad de funciones kernel usadas; \mathbf{x}_d son los centros de las funciones kernel; y $\mathbf{w} = [w_0, w_1, \dots, w_N]'$ es el vector de parámetros del modelo. La función $\varphi(\cdot, \cdot)$ representa una de las funciones kernel descritas en la Tabla I donde α y r representan parámetros.

Tabla 1. Principales Funciones Kernel

Nombre	Definición
LINEAL [64] [78]	$\varphi(\mathbf{x}_t, \mathbf{x}_d) = \mathbf{x}_t \cdot \mathbf{x}_d$
POLINOMIAL DE GRADO d [64] [78]	$\varphi(\mathbf{x}_t, \mathbf{x}_d) = (\alpha \mathbf{x}_t \cdot \mathbf{x}_d + r)^d$ con $\alpha > 0$
GAUSSIANA O RBF [62] [64] [55] [53]	$\varphi(\mathbf{x}_t, \mathbf{x}_d) = \exp\left(-\frac{\ \mathbf{x}_t - \mathbf{x}_d\ ^2}{2\sigma^2}\right)$
EXPONENCIAL	$\varphi(\mathbf{x}_t, \mathbf{x}_d) = \exp\left(-\frac{1}{\sigma^2}(\ \mathbf{x}_t - \mathbf{x}_d\)\right)$
SIGMOIDEA [64] [47]	$\varphi(\mathbf{x}_t, \mathbf{x}_d) = \tanh(\alpha \mathbf{x}_t \cdot \mathbf{x}_d + r)$

La estimación de los parámetros de la SVM se realiza mediante la minimización de la función de riesgo regularizado. En el caso más común en la literatura, se utiliza la función ε -insensible definida como:

$$L_\varepsilon(y_t, \hat{y}_t) = \begin{cases} |y_t - \hat{y}_t| & \text{cuando } |y_t - \hat{y}_t| \geq \varepsilon \\ 0 & \text{en caso contrario} \end{cases}$$

tal que la función de riesgo regularizado $R(C, \varepsilon)$ es expresada como:

$$R(C, \varepsilon) = C \frac{1}{T} \sum_{t=1}^T L_\varepsilon(y_t, \hat{y}_t) + \frac{1}{2} \sum_{d=0}^N w_d^2$$

donde el primer sumando representa el error de ajuste entre el valor real y_t y el pronosticado \hat{y}_t y el segundo representa una penalización debida a la magnitud de los parámetros. El problema en la estimación radica en que se deben seleccionar valores apropiados de C y ε para poder estimar posteriormente los parámetros óptimos w [52] [53].

3 METODOLOGÍA

A continuación se describe la metodología de investigación empleada la cual está basada en la revisión sistemática de documentos. Como base de datos bibliográfica se usó el servicio Scopus de Elsevier. La cadena de búsqueda utilizada se construyó a partir de las palabras clave suministradas en artículos sugeridos en la preparación inicial de la investigación. La cadena utilizada fue la siguiente:

```
(TITLE-ABS-KEY (support vector machine)
OR TITLE-ABS-KEY (support vector regression)
OR TITLE-ABS-KEY (SVM)
OR TITLE-ABS-KEY (SVMs)
OR TITLE-ABS-KEY (SVR)
OR TITLE-ABS-KEY (SVRs))
AND TITLE-ABS-KEY(time series)
AND (TITLE-ABS-KEY(financial) OR TITLE-ABS-KEY(finance))
AND (TITLE-ABS-KEY(forecast) or TITLE-ABS-KEY(forecasting) OR TITLE-ABS-
KEY(predict) OR TITLE-ABS-KEY(prediction))
```

La búsqueda se limitó a las publicaciones hasta el año 2014 (inclusive). Igualmente se limitaron las áreas de conocimiento a las siguientes.

- Businesses, Management and Accounting
- Computer Sciences
- Decision Sciences
- Economics, Econometrics and Finance
- Mathematics
- Social Sciences

Por otra parte, únicamente se consideraron artículos en revistas indexadas y artículos de conferencia. Finalmente, sólo se incluyeron artículos en inglés.

Se definieron los siguientes criterios de inclusión los cuales debían ser satisfechos simultáneamente para que una publicación sea considerada en la investigación:

- La SVM o SVR son aplicadas, al menos, a una serie de tiempo financiera o económica.
- El artículo contiene un elemento novedoso sobre el caso de uso o sobre las SVM.

- El artículo reporta explícitamente el aporte realizado.

Se consideraron los siguientes criterios de exclusión:

- En el artículo se realiza únicamente la aplicación de una metodología bien conocida a un caso de predicción; es decir, con este criterio se busca descartar estudios que reportan casos triviales de aplicación.
- En el artículo se discuten temas financieros pero que no son propiamente series de tiempo financieras.
- El artículo presenta casos, resultados o conclusiones que ya fueron publicados en estudios previos.

De los artículos finalmente seleccionados se recopiló la siguiente información:

- Autores.
- Nombre de la revista o conferencia.
- Año de publicación.
- Citaciones al artículo.
- Tipos de casos de estudio.
- Algoritmos de optimización utilizados.
- Tipo de función de optimización del algoritmo.
- Medidas de ajuste.
- Modelos de comparación de desempeño.

4 RESULTADOS OBTENIDOS

Se recuperaron 188 documentos de forma automática al aplicar la metodología descrita en la sección anterior. Para aplicar los criterios de inclusión y exclusión, se realizó una revisión manual del título, el resumen y las palabras clave de los artículos, lo que permitió seleccionar finalmente 59 documentos para dar respuesta a las preguntas de investigación propuestas.

Se publicaron 34 (56%) artículos en revistas indexadas y los 25 (44%) restantes en memorias de congresos. Los 59 documentos seleccionados se encuentran publicados en 47 fuentes diferentes mostrando una gran dispersión en las fuentes de publicación. Las revistas en las que más se publica son: *Expert Systems with Applications* (6 artículos), *Neural Computing and Applications* (3 artículos), *Neurocomputing* (2 artículos), *Economic Modelling* (2 artículos) e *IEEE Transactions on Neural Networks* (2 artículos). La participación más activa en congresos se da en la *International Joint Conference on Neural Networks* (2 trabajos) y en la *IEEE International Conference on Neural Networks* (2 trabajos).

En la Figura 1 se presenta la cantidad de documentos publicados por año. Se aprecia que la publicación de artículos entre el año 2000 y el año 2008 fue de crecimiento lento, llegándose a un máximo de 11 artículos publicados en el año 2009. Entre los años 2010 y 2014 el comportamiento es diferente: la publicación de los artículos muestra un descenso lento, aunque se mantiene por encima de cuatro (4) artículos publicados por año. En promedio se publican cuatro (4) artículos anualmente.




Fig. 1 Cantidad de trabajos publicados por año.

La localización de artículos relevantes al tema parece ser difícil. Existe una gran cantidad y dispersión de palabras clave usadas en los artículos seleccionados; se encontraron un total de 160 palabras clave diferentes. En la Figura 2 se presenta un histograma con las palabras claves más usadas, siendo

financial data processing y financial time series las dos palabras clave más relevantes al tema del pronóstico financiero.

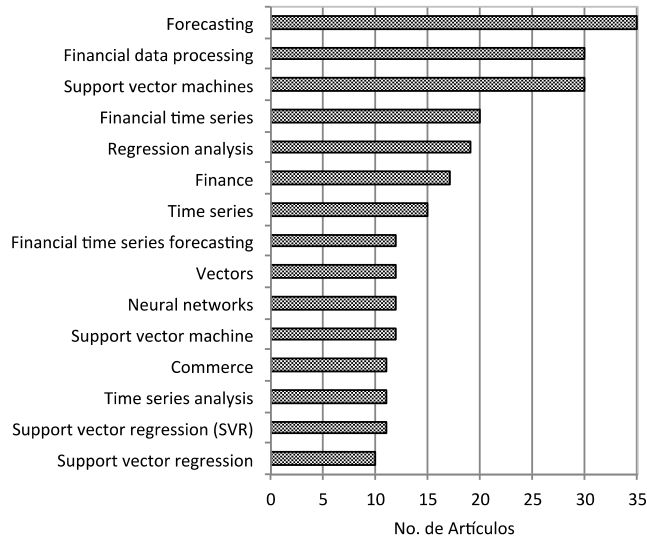


Fig. 2 Principales palabras clave usadas en los artículos seleccionados.

Los 59 artículos seleccionados fueron elaborados por un total de 137 autores. En la Tabla II se resume el número total de autores de acuerdo con la cantidad de artículos publicados; en ella se aprecia que hay poca continuidad sobre el tema, ya que el 88% de los autores solo ha escrito un artículo. En la Figura 3 se listan los primeros 15 autores con más artículos publicados; como se puede observar en dicha figura, la mayor producción de artículos se concentra en China, seguida por Taiwan y Estados Unidos. Respecto al país de origen de las instituciones, claramente China lidera la investigación al respecto (véase la Figura 4); consecuentemente con lo anterior, la institución con la mayor cantidad de artículos publicados es la Universidad Nacional de Singapur (véase la Figura 5).

Tabla 2. Principales Funciones Kernel

Cantidad de Artículos publicados	Numero de Autores
4	1
3	2
2	13
1	121

En la Tabla III se listan los artículos con 20 o más citas; Mientras que el trabajo de Kim [54] es el más citado, los investigadores L. Cao y F. E. H. Tay son autores de cuatro trabajos que aparecen en la lista [51] [52] [55] [56] sumando un total de 544 citas. Se puede decir que la publicación

sobre el pronóstico de series financieras usando SVMs parece tener un potencial de citación alto: 45 documentos fueron citados, al menos, una vez. Los tres trabajos más citados fueron publicados en las revistas Neurocomputing (ref. [54]) y IEEE Transactions on Neural Networks (refs. [5] [52])

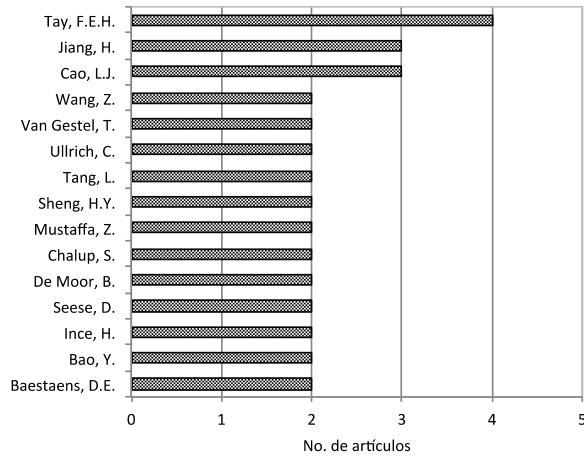


Fig. 3 Autores con la mayor cantidad de artículos publicados.




Fig. 4 Total de artículos publicados por país de origen de las instituciones.

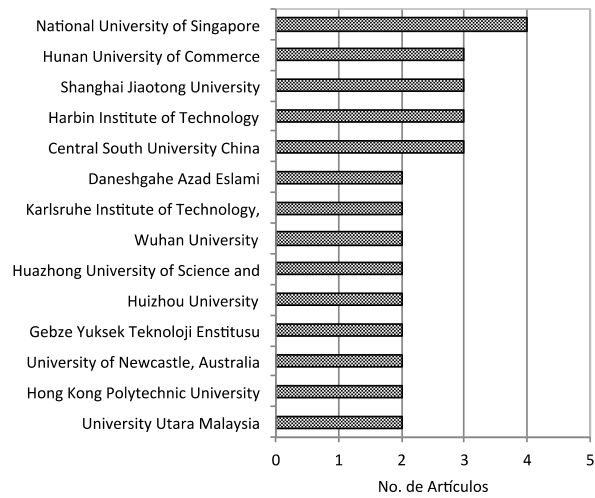


Fig. 5 Total de artículos publicados por filiación de los autores.

Tabla 3. Artículos y número de citaciones

Autor	Título	Año	Citaciones
Lin C. S.. [55]	Empirical Mode Decomposition-Based Least Squares Support Vector Regression for foreign exchange rate forecasting	2003	310
Cao L. J.. [40]	Support vector machine with adaptive parameters in financial time series forecasting	2003	262
Chang B. R.. [18]	Financial prediction applications using Quantum-Minimized Composite model ASVR/NGARCH	2001	214
Cheng Y.. [24]	A hybrid support vector regression based on chaotic particle swarm optimization algorithm in forecasting financial returns	2009	43
Kim K. J.. [58]	Financial time series forecasting using support vector machines	2001	30
Wu C.. [38]	Application of support vector machines in paying rate forecasting	2009	26
Hung W. M.. [13]	Application of SVR with improved ant colony optimization algorithms in exchange rate forecasting	2009	26
Tay F. E. H.. [41]	ϵ -Descending support vector machines for financial time series forecasting	2002	26
Ince H.. [16]	Non-parametric regression methods	2006	20
Pai P. F.. [20]	Predicting movement directions of stock index futures by support vector models with data preprocessing	2009	15
Xiong T.. [63]	Multiple-output support vector regression with a firefly algorithm for interval-valued stock price index forecasting	2014	9
Wei S.. [23]	Stock return forecast with LS-SVM and particle swarm optimization	2008	9
Zhiqiang G.. [2]	Financial time series forecasting using LPP and SVM optimized by PSO	2013	8
Bao Y.. [22]	Forecasting stock price by SVMs regression	2004	7

Autor	Título	Año	Citaciones
Wu J. L.. [36]	A trend-based segmentation method and the support vector regression for financial time series forecasting	2012	5
Hossain A.. [29]	Comparison of the finite mixture of ARMA-GARCH, back propagation neural networks and support-vector machines in forecasting financial returns	2010	5
Cheng C. H.. [17]	A novel time-series model based on empirical mode decomposition for forecasting TAIEX	2014	4
Van Gestel T.. [9]	Financial time series prediction using least squares support vector machines within the evidence framework	2006	4
Tang L. B.. [21]	GARCH prediction using spline wavelet support vector machine	2009	4
Jiang H.. [26]	Grey relational grade in local support vector regression for financial time series prediction	2012	4
Luo F.. [14]	A novel nonlinear combination model based on support vector machine for stock market prediction	2010	3
Tang L.. [19]	Forecasting stock returns based on spline wavelet support vector	2009	2
Jiang H.. [6]	GM-RVVM-SVR model for financial time series forecasting	2010	2
Tay F. E. H.. [33]	Improved financial time series forecasting by combining Support Vector Machines with self-organizing feature map	2011	2
Xiao Y.. [25]	Improving financial returns using neural networks and adaptive particle swarm optimization	2012	2
Yang H.. [62]	Localized support vector regression for time series prediction	2009	2
Ullrich C. [4]	Predicting foreign exchange rate return directions with support vector machines	2005	2
Khemchandani R.. [65]	Regularized least squares fuzzy support vector regression for financial time series forecasting	2006	2
Cai C.. [7]	Research on support vector regression in the stock market forecasting	2005	2
Wang F.. [34]	Stock market volatility prediction A service-oriented multi-kernel learning approach	2012	2
Kazem A.. [12]	Support vector regression with chaos-based firefly algorithm for stock market price forecasting	2013	2
Van Gestel T.. [44]	Volatility tube Support Vector Machines	2000	2
Cao Y.. [52]	A novel portfolio optimization method for foreign currency investment	2010	1
Hsu S. H.. [53]	A two-stage architecture for stock price forecasting by integrating self-organizing map and support vector regression	2013	1
Huang S. C.. [8]	Chaos-based support vector regressions for exchange rate forecasting	2011	1
Huang C.. [57]	Financial time series forecasting based on wavelet kernel support vector machine	2011	1
Yuan Y.. [60]	Forecasting the movement direction of exchange rate with polynomial smooth support vector machine	2013	1
Ullrich C.. [15]	Foreign exchange trading with Support Vector Machines	2007	1
Shao X.. [64]	ℓ_p -norm multikernel learning approach for stock market price forecasting	2012	1
Mustaffa Z.. [28]	LSSVM parameters tuning with enhanced artificial bee colony	2014	1

Autor	Título	Año	Citaciones
De Brito. [5]	A foreign exchange market trading system by combining GHSOM and SVR	2012	0
Kao L. J.. [43]	A hybrid approach by integrating wavelet-based feature extraction with MARS and SVR for stock index forecasting	2013	0
Huang C. L.. [49]	A hybrid SOFM-SVR with a filter-based feature selection for stock market forecasting	2013	0
Mustaffa Z.. [11]	A hybridization of enhanced artificial bee colony-least squares support vector machines for price forecasting	2010	0
Khatibi V.. [1]	A new support vector machine- genetic algorithm (SVM-GA) based method for stock market forecasting	2012	0
Sui X. S.. [51]	A novel feature selection approach using classification complexity for SVM of stock market trend prediction	2011	0
Wang D.. [39]	A novel nonlinear RBF Neural Network ensemble model for financial time series forecasting	2008	0
Wang B.. [35]	A support vector machine based MSM model for financial short-term volatility forecasting	2009	0
Li Z.. [46]	Adaptively weighted support vector regression for financial time series prediction	2014	0
Duan W. Q.. [45]	Cross-correlation and the predictability of financial return series	2006	0
Cao L. J.. [37]	Financial forecasting using Support Vector Machines	2010	0
Wang L.. [56]	Financial market forecasting using a two-step kernel learning method for the support vector regression	2009	0
Jiang H.. [27]	Financial time series prediction based on grey model integrated with support vector regression	2008	0
Wan C.. [3]	Research on the prediction of Stock market based on chaos and SVM	2014	0
Ince H.. [42]	Short term forecasting with support vector machines and application to stock price prediction	2007	0
Lai L. K. C.. [66]	Stock forecasting using Support Vector Machine	2012	0
Chen J.. [31]	SVM application of financial time series forecasting using empirical technical indicators	2010	0
Lin J.. [67]	The prediction of stock index based on fuzzy wavelet analysis	2007	0
Tang L.. [32]	Wavelet kernel function for stock index forecast	2009	0

5 DISCUSIÓN.

A continuación se responden las preguntas de investigación propuestas en este trabajo.

5.1 ¿Cuáles son las arquitecturas (funciones de núcleo) de SVM para las que se han reportado resultados en el pronóstico de series de tiempo financieras?

En la Tabla IV se listan las funciones de núcleo utilizadas. La función de base radial o RBF es la más utilizada. La elección de la función de núcleo tiene un gran impacto en el desempeño de la SVM. La función RBF tiene como atributos que puede transformar el espacio de entrada a un espacio superior; y es adecuada para manejar aquellos casos en que la relación entre las variables de entrada y salida no tiene una relación lineal. De las funciones de núcleo listadas en la Tabla I, RBF es la función que presenta el menor número de hiper-parámetros a ser cuantificados lo que facilita la estimación de los parámetros óptimos de la SVM. En el caso de la función spline, los documentos muestran que esta técnica mejora el desempeño de SVM al capturar la estacionalidad de las series de tiempo.

Tabla 4. Funciones de núcleo utilizadas.

Función	Número de trabajos	Porcentaje	Refs.
RBF	47	71%	[2] [3] [4] [5] [7] [8] [9] [10] [12] [23] [36] [37] [38] [39] [40] [41] [43] [44] [45] [47] [48] [49] [52] [54] [55] [56] [57] [58] [59] [61] [65] [66] [67] [68] [69] [70] [71] [74] [75] [76] [77] [78] [79] [80]
POLINOMIAL	6	9%	[10] [13] [51] [58] [60] [77]
SPLINE	6	9%	[42] [50] [53] [63] [72] [81]
LINEAL	3	3%	[3] [73]
SIGMOIDEA	2	1%	[70] [81]
GAUSSIANA	2	1%	[11] [62]
MULTINUCLEO	2	1%	[46] [73]
TANGENTE	1	1%	[37]

5.2 ¿Qué metodologías se han usado para estimar los parámetros de SVM?

La metodología de estimación de parámetros depende en gran medida del tipo de función de error utilizada. De acuerdo con los trabajos analizados, la función de pérdida ϵ -insensible de Vapnik es la más usada [4] [5] [6] [38] [39] [40] [41] [44] [47] [49] [50] [52] [55] [56] [57] [58] [59] [65]. En [40] y [60] se usó la función ϵ -descendente; en [61] se usaron una variación de la función ϵ -insensible y la función de Hinge.

En algunos de los trabajos, los valores óptimos de C y ϵ fueron definidos por criterio experto del pronosticador [12] [62] [63] [36] [46], mientras que en los casos restante dichos valores fueron estimados dentro del proceso de optimización. El proceso de optimización puede ser realizado por técnicas muy simples como la búsqueda sobre una malla de valores discretos de C y ϵ [46] [47] [53] [58] [61] [64] [65], técnicas heurísticas como el patrón de búsqueda [2] [41] o técnicas de gradiente [60]; inclusive, algunos trabajos han propuesto el uso de parámetros adaptativos [52]. Para garantizar la robustez de la selección de los valores de los parámetros, muchos estudios recomiendan el uso de la técnica de validación cruzada [3] [9] [42] [43] [46] [53] [61] [62] [63] [64] [66] [67] [68]. Para realizar la optimización también se han aplicado técnicas heurísticas que incluyen la búsqueda tabú [45] y diferentes algoritmos poblacionales como los enjambres de partículas [9] [13] [37], de abejas [38] [39] y de hormigas [23].

5.3 ¿Cuáles son los tipos de series de tiempo financieras que se han pronosticado?

En la Tabla V se resume la información sobre el tipo de series financieras pronosticadas. Se han realizado predicciones para 183 series de tiempo financieras, de las cuales, 101 series corresponden a precios de acciones o a índices financieros, lo que señala que la mayor parte de la investigación se centra sobre este tipo de series. Los índices financieros más pronósticos son: SSE (11 casos), S&P500 (10 casos), Nikkei (9 casos), el DJ (7 casos) y el FTSE100 (6 casos). El SSE y el S&P500 son los índices financieros más importantes de las bolsas de Shanghai y Estados Unidos respectivamente. Igualmente, se puede concluir que existe un mayor interés en el pronóstico de tasas de cambio respecto a las tasas de interés, índices inflacionarios, precios de commodities e índices técnicos. En relación a las tasas de interés, se prefiere pronosticar la GBP/USD (6 casos) y la EUR/USD (3 casos) que son las más representativas del mercado de capitales europeo.

Tabla 5. Tipos de Series Financieras Pronosticadas

Tipo de Serie	Número de trabajos	%	Referencias.
ÍNDICE FINANCIERO	80	50,6%	[2] [3] [5] [6] [7] [8] [9] [10] [12] [13] [23] [36] [37] [39] [40] [41] [42] [43] [45] [46] [47] [48] [49] [50] [52] [53] [55] [56] [54] [58] [59] [60] [61] [64] [66] [69] [70] [72] [73] [75] [76] [77] [78] [79] [80] [81]
PRECIO DE ACCIÓN	31	19,6%	[8] [44] [57] [63] [13] [58] [67] [77]
TASA DE CAMBIO	24	15,2%	[4] [11] [12] [23] [39] [43] [62] [65] [74]
TASA DE INTERÉS	17	10,8%	[4] [11] [12] [23] [39] [43] [62] [65] [74]
INFLACIÓN	3	1,9%	[38] [48] [78]
COMMODITY	2	1,3%	[79]
ÍNDICE TÉCNICO	1	0,6%	[40]

En la Tabla 6 se muestran en detalle el nombre de las series de tiempo y el tipo de serie que fueron estudiadas en los documentos de revisión

Tabla 6. Nombre de las series de tiempo financieras pronosticadas y su clasificación

Tipo de Serie	Nombre	# de veces pronosticada	% de veces pronosticada
COMMODITY	PN21	1	0,6%
	CRB	1	0,6%
ÍNDICE FINANCIERO	AU	1	0,63%
	BVSP	1	0,63%
	D1-SP	1	0,63%
	D2-SP	1	0,63%
	DAX30	5	3,16%
	DJ	7	4,43%
	FTSE 100	6	3,80%
	Gold	1	0,63%
	Haier	1	0,63%
	Hang Seng Index	1	0,63%
	HS	1	0,63%
	HSI	2	1,27%
	KO	1	0,63%
	KOSPI	1	0,63%
	MATIF-CAC44	3	1,90%
NASDAQ	4	2,53%	
Nikkei	9	5,70%	
S&P 500	10	6,33%	
SHCOMP	2	1,27%	
SICOM	1	0,63%	

Tipo de Serie	Nombre	# de veces pronosticada	% de veces pronosticada
	SPCOMP	3	1,90%
	SSEC	11	6,96%
	SXGE	1	0,63%
	SZSC	1	0,63%
	SZSE	1	0,63%
	TAIEX	1	0,63%
	TSIF	1	0,63%
	TW	1	0,63%
ÍNDICE TÉCNICO	ST	1	0,6%
INFLACIÓN	IGIP	2	1,3%
	MGOVI	1	0,6%
PRECIO DE ACCIÓN	AAPL	1	0,63%
	ABLE	1	0,63%
	AMNB	1	0,63%
	AMZN	1	0,63%
	BA	1	0,63%
	CAT	1	0,63%
	CSCO	1	0,63%
	CTGBZ	1	0,63%
	Eric	1	0,63%
	FCEL	1	0,63%
	FITX	1	0,63%
	GEOI	1	0,63%
	GOOG	1	0,63%
	IBM	1	0,63%
	INTC	2	1,27%
	ISE 100	1	0,63%
	JPY/NTD	2	1,27%
	MCEL	1	0,63%
	MSFT	3	1,90%
	Redhat Software	1	0,63%
	SONS	1	0,63%
	VOLV-B.ST	4	2,53%
	VZ	1	0,63%
	XOM	1	0,63%
	YHOO	1	0,63%
TASA DE INTERÉS	CBOT-BO	3	1,9%
	CBOT-US	3	1,9%
	CME-SP	2	1,3%

Tipo de Serie	Nombre	# de veces pronosticada	% de veces pronosticada
	EUREX-BUN	2	1,3%
	EUREX-BUND	1	0,6%
	FRCAC40	3	1,9%
	Paying rate index	1	0,6%
	Santa Fe	1	0,6%
	T-bill	1	0,6%
TIPO DE CAMBIO	ADD/USD	1	0,63%
	AUD/USD	1	0,63%
	CHF/USD	1	0,63%
	DM/USD	1	0,63%
	EDR/USD	1	0,63%
	ESD/USD	1	0,63%
	EUR/JPY	1	0,63%
	EUR/USD	3	1,90%
	FF/USD	1	0,63%
	GBP/USD	6	3,80%
	JPY/USD	1	0,63%
	LIT/USD	1	0,63%
	NZD/USD	1	0,63%
	RMB/NTD	1	0,63%
	RMB/USD	1	0,63%
	RUB/USD	1	0,63%
	USD/NTD	1	0,63%

5.4 ¿Qué periodicidad reportan estas series de tiempo?

Las series de tiempo reportan diferentes ventanas de tiempo y por lo general, estas tienen periodicidad diaria. A continuación se muestra en detalle la periodicidad de las series de tiempo reportadas:

- Intradía (3 series que representan el 2%),
- Diaria (138 series que representan el 87%)
- Semanales (8 series que representan el 5%).
- Quincenal (2 series que representan el 1%).
- Mensual (4 series que representan el 3%),
- Anual (3 series que representan el 2%)

5.5 ¿Qué tipos de transformaciones se aplicaron a las series de tiempo?

Se encontró que el tipo de transformación utilizada depende en gran medida del criterio del experto y no hay recomendaciones aceptadas de forma unánime por la comunidad. También se encontró diversidad en los tipos de entradas de la SVM: mientras en el caso más simple, una serie de tiempo puede ser pronosticada usando sus valores pasados, muchos de los trabajos analizados proponen incorporar como entradas algún tipo de indicador calculado con base en los datos. Estos indicadores permiten aislar información sobre la tendencia (u otras características) que no es fácilmente detectable y que permite aumentar la precisión del pronóstico.

En la mayor parte de los casos se usaron los rendimientos discretos o logarítmicos [5] [6] [39] [42] [47] [50] [51] [58] [63] [64] [69] [70] [72]. Otra elección común es la estandarización de los datos [5] [9] [10] [11] [38] [39] [46] [52].

En la literatura analizada se han calculado los indicadores descritos a continuación a partir de los datos originales o los rendimientos discretos, logarítmicos o estandarizados. Estos indicadores son usados como entrada a la SVM con el fin de pronosticar la serie de interés. Los indicadores calculados comúnmente usados son: la media móvil simple [36] [47] [53] [68] [74] y exponencial [56] [58] [63] [64] [68] [70] [73]; la desviación entre la serie y su media móvil [68]; el índice de fuerza relativa (RSI) [45] [46] [54] [57] [58] [67] [68] [75]; el índice MACD [12] [45] [47] [58] [55] [56] [67] [68] [75]; el indicador %R de Larry William [8] [46] [47] [54] [58] [68] [75].

En la Tabla 7 se describen las principales transformaciones usadas en la literatura que fueron aplicadas para obtener mejores desempeños.

Tabla 7. Principales transformación de las series

Transformación	Citaciones	Formula.
DIFERENCIA PORCENTUAL RELATIVA (RELATIVE DIFFERENCE IN PERCENTAGE RDP, POR SUS SIGLAS EN INGLÉS).	[5], [19], [22], [34], [37], [40], [41], [57], [60]	$R = (P_{t+1} - P_t)/P_t$
MEDIA MÓVIL (MOVING AVERAGE MA, POR SUS SIGLAS EN INGLÉS)	[23], [31], [43], [54], [59]	$MA(n) = (1/n) * \sum_{i=t-n+1}^t C_i$
BIAS ES UN INDICADOR QUE MIDE EL NIVEL DE DESVIACIÓN ENTRE EL PRECIO DE CIERRE Y EL PROMEDIO MÓVIL	[59]	$BIAS(n)_t = (C_t - MA_n)/MA_t * 100$
INDICADOR DE FUERZA RELATIVA (RELATIVE STRENGTH INDEX RSI, POR SUS SIGLAS EN INGLÉS)	[16], [20], [34], [36], [42], [50], [59], [62]	$RSI(n)_t = (UPC_n/UD_n)/((UPC_n/UD_n) + (DPC_n/DD_n)) * 100$
PROMEDIO MÓVIL CONVERGENTE/DIVERGENTE (MOVING AVERAGE CONVERGENCE/DIVERGENCE MACD, POR SUS SIGLAS EN INGLÉS)	[5], [20], [31], [36], [37], [41], [42], [59], [62]	$MACD(n)_t = EMA(C_t, 12) - EMA(C_t, 26)$

Transformación	Citaciones	Formula.
ESTOCÁSTICO K COMPARA EL PRECIO DE CIERRE RELATIVO EN RELACIÓN CON UN RANGO DE PRECIOS DE UN PERÍODO DE TIEMPO DADO. (STOCHASTIC DAY %K)	[20], [34], [36], [59]	$\%K = (C_t - LL_{t-n}) / (HH_{t-n} - LL_{t-n}) * 100$
ESTOCÁSTICO D MEDIA MÓVIL DE K (STOCHASTIC DAY %D)	[20], [34], [36], [59]	$\%D = \sum_{i=0}^{n-1} \%K_{t-i} / n$
TASA DE PRECIO DE CAMBIO (PRICE RATE-OF-CHANGE ROC, POR SUS SIGLAS EN INGLÉS). MUESTRA EL DIFERENCIA DE PRECIO ENTRE EL PRECIO ACTUAL Y EL PRECIO N HACE DÍAS	[1], [50]	$ROC = C_t / C_{t-n} * 100$
LARRY WILLIAM %R QUE ES UN INDICADOR DE MOMENTO QUE MIDE LOS NIVELES DE SOBRECOPRA /SOBREVENTA. (WILLIAMS' %R, POR SUS SIGLAS EN INGLÉS)	[1], [31], [34], [36], [50], [59], [62]	$\%R = (H_n - C_t) / (H_n - L_n) * 100$
OSCILADOR DE ACUMULACIÓN/DISTRIBUCIÓN ES UN INDICADOR DE MOMENTO QUE ASOCIA LOS CAMBIOS EN LOS PRECIOS. (ACCUMULATION/DISTRIBUTION OSCILLATOR A/D POR SUS SIGLAS EN INGLÉS)	[16], [50], [62]	$A/D = (H_t - C_{t-1}) / (H_t - L_t) * 100$
DISPARIDAD QUE SIGNIFICA LA DISTANCIA ENTRE EL PRECIO ACTUAL Y LA MEDIA MÓVIL DE T DÍAS	[1], [14], [39], [45], [50]	$D5 = C_t / MA_5 * 100$
OSCILACIÓN DEL PRECIO QUE MUESTRA LA DIFERENCIA ENTRE EL PRECIO DE DOS MEDIAS MÓVILES (PRICE OSCILLATOR OSCP POR SUS SIGLAS EN INGLÉS)	[50]	$OSCP = MA_5 - MA_{10} / MA_5 * 100$
LÍNEA PSICOLÓGICA DE 10 DÍAS (10-DAY PSYCHOLOGICAL LINE PSY10 POR SUS SIGLAS EN INGLÉS)	[4], [20], [23], [34], [59]	$PSY(n)_t = UD_n / n * 100$
MOVIMIENTO DE LA VARIANZA (MOVING VARIANCE MV, POR SUS SIGLAS EN INGLÉS)	[14]	$MV(n) = \sum_{i=t-n+1}^{n-1} C_i - \hat{C}_i / n$

5.6 ¿Cuáles fueron los modelos utilizados para comparar la capacidad predictiva de SVM?

Existe una gran diversidad en los tipos de modelos usados para comparar la capacidad predictiva de las SVM, existiendo casos en los que no se realizan comparaciones como los de Bao, Lu y Zhang [64] y Yuan [60]. Ya que en muchos trabajos se proponen mejoras a los modelos más clásicos de

SVM, resulta natural que en muchos de ellos se evalué la versión tradicional contra la versión mejorada, como por ejemplo en [10] [11] [41] [50] [62] [70] [72] [73].

Entre los métodos alternativos de pronóstico considerados por los investigadores se encuentran el paseo aleatorio [23] [48], las redes neuronales artificiales (usualmente del tipo perceptrón multicapa) [4] [8] [13] [23] [36] [37] [39] [43] [44] [45] [52] [54] [55] [57] [61] [62] [66] [67] [70] [71] [74] [76], los modelos ARIMA y sus variantes [5] [11] [13] [43] [53] [62] [65] [67] [69] [76]; los modelos neurodifusos como ANFIS [44] [53] [70] [76]; las redes neuronales autoasociativas [75]; y MARS [53].

En la Tabla 8 se describen los modelos contra los que fue comparada la SVM

Tabla 8. Modelos de Comparación Predictiva de SVM

Cita	Modelo de comparación
[22]	No compara contra un modelo
[7]	Máquina de vectores de soporte. SVM
[40]	Red neuronal con propagación hacia atrás. BP-NN
[37]	Red neuronal de propagación hacia adelante. RBFNN Red neuronal con propagación hacia atrás. BP-NN Red neuronal con transformada ondícula. WBP
[54]	Rede neuronal de perceptrón múltiple. NN-MLP Promedio móvil simple 50. SMA50 Promedio móvil simple 200. SMA200
[18]	Modelo gris. GM Modelo autorregresivo de media móvil. ARMA Red neuronal de propagación hacia adelante. RBFNN Sistemas adaptativos de inferencia neurodifusa. ANFIS Máquina de vectores de soporte para regresión. SVR Modelos de heterocedasticidad condicional autorregresiva no lineal generalizada y máquinas de vectores de soporte para regresión adaptativas. RGA-ASVR/NGARCH
[31]	SVM con la serie original
[17]	Modelo autorregresivo. AR Épsilon-insensible y máquinas de vectores de soporte para regresión. ϵ -SVR
[24]	Red neuronal con propagación hacia atrás. BP-NN Modelo autorregresivo integrado de media móvil. ARIMA
[5]	Estrategia de comprar y retener. BUY-AND-HOLD (B&H) Máquina de vectores de soporte para regresión. SVR
[45]	Modelo de caminata aleatoria. RW
[29]	Modelo autorregresivo de media móvil. ARMA Modelo de heterocedasticidad condicional autorregresiva no lineal generalizada. GARCH

Cita	Modelo de comparación
	Red neuronal con propagación hacia atrás. BP-NN
[55]	Máquina de vectores de soporte. SVM
[56]	Máquina de vectores de soporte con función de núcleo polinomio Máquina de vectores de soporte con función de núcleo gaussiana Máquina de vectores de soporte con función de núcleo Morlet Función de núcleo con transformada ondícula gaussiana Función de núcleo con transformada ondícula spline biortogonal
[59]	Máquina de vectores de soporte para regresión. SVR
[8]	Red neuronal. NN Máquina de vectores de soporte. SVM Teoría del caos y red neuronal. Chaos-BPNN
[13]	Algoritmos genético y máquina de vectores de soporte. HSVMG Red neuronal. NN Aproximación local lineal del vector de valor. VLLR Modelo de caminata aleatoria. RW
[16]	Perceptrón multicapa. MLP Modelos de heterocedasticidad condicional autorregresiva. GARCH Modelos de heterocedasticidad condicional autorregresiva exponencial. EGARCH Modelos de heterocedasticidad condicional autorregresiva en media. GARCH-M
[42]	Perceptrón multicapa. MLP Modelo autorregresivo integrado de media móvil. ARIMA
[26]	Modelo gris. GM Modelo gris con modelo puesto a punto y operación de generación acumulada. GM-R-IAGO Modelo gris con modelo puesto a punto y optimización. GM-R-OS
[6]	Modelo gris con modelo puesto a punto con raíz m. m-root GM Modelo gris con modelo puesto a punto. GMRVV Modelo gris con modelo puesto a punto y Máquina de soportes de vectores para regresión. GMRVV-SVgR
[27]	Máquina de vectores de soporte para regresión. SVR Máquina de vectores de soporte local para regresión. LD-SVR
[43]	Transformación ondícula y máquinas de vectores de soporte para regresión. W-SVR Transformación ondícula con splines adaptativas de regresión multivariable. Wavelet-MARS Modelo autorregresivo integrado de media móvil. ARIMA Máquina de vectores de soporte para regresión. SVR Sistemas adaptativos de inferencia neurodifusa. ANFIS
[12]	Algoritmo genético con máquinas de vectores de soporte para regresión. SVR-GA Algoritmo genético con teoría del caos y máquinas de vectores de soporte para regresión. SVR-CGA Algoritmo de optimización de luciérnaga y máquinas de vectores de soporte para regresión. SVR-FA Red neuronal artificial. ANNs Sistemas adaptativos de inferencia neurodifusa. ANFIS
[1]	Algoritmo de optimización por enjambre de partículas. PSO Perceptron multicapa. MLP

Cita	Modelo de comparación
	Red neuronal. NN
[52]	Máquina de vectores de soporte para regresión. SVR
[50]	Red neuronal con propagación hacia atrás. BP-NN Razonamiento basado en casos. CBR
[60]	Red neuronal con propagación hacia atrás. BP-NN Máquina de vectores de soporte con función de núcleo sigmoidea Máquina de vectores de soporte con función de núcleo hiperbólica tangente Máquina de vectores de soporte con función de núcleo de base radial Máquina de vectores de soporte con función de núcleo lineal Máquina de vectores de soporte con función de núcleo polinomio Máquina de vectores de soporte con función de núcleo de Laplace Máquina de vectores de soporte con función de núcleo de Bessel Máquina de vectores de soporte con función de núcleo p-gaussiana Fast Prop tangente hiperbólica Fast Prop sigmoidea Fast Prop Lineal Fast Prop de función de base radial Neuro difuso. Neuro-Fuzzy.
[46]	Máquina de vectores de soporte para regresión. SVR
[49]	Descomposición empírica en modos y modelo autorregresivo integrado de media móvil. EMD-ARIMA Mínimos cuadrados y máquinas de vectores de soporte para regresión. LSSVR Modelo autorregresivo integrado de media móvil. ARIMA
[61]	SVM con la serie original
[14]	Combinación de modelo con regresión lineal. LR-CM
[28]	Algoritmo de optimización de la colonia artificial de abejas con mínimos cuadrados. ABC-LSSVM Red neuronal con propagación hacia atrás. BP-NN
[11]	Algoritmo de optimización de la colonia artificial de abejas con mínimos cuadrados y máquinas de vectores de soporte. ABC-LS-SVM Validación cruzada con mínimos cuadrados y máquinas de vectores de soporte. CV-LSSVM
[20]	Red neuronal con propagación hacia atrás. BP-NN
[57]	Máquina de vectores de soporte con función de núcleo simple. SKSVR
[62]	ASH Red neuronal asociativa. ASNN Vecinos más próximos ND Decisión de error de los Vecinos más próximos. NDEM
[19]	Red neuronal con propagación hacia atrás. RBF
[32]	Máquina de vectores de soporte con función de núcleo p-gaussiana
[21]	Máquina de vectores de soporte con función de núcleo gaussiana. GK-SVM
[41]	Máquina de vectores de soporte. SVM
[33]	Máquina de vectores de soporte. SVM

Cita	Modelo de comparación
[4]	<p>Modelo Naïve</p> <p>Modelo de media móvil. MA</p> <p>Máquina de vectores de soporte con función de núcleo lineal</p> <p>Máquina de vectores de soporte con función de núcleo polinomio</p> <p>Máquina de vectores de soporte con función de núcleo de base radial</p> <p>Máquina de vectores de soporte con función de núcleo hiperbólica</p> <p>Máquina de vectores de soporte con función de núcleo de Laplace</p> <p>Máquina de vectores de soporte con función de núcleo de Bessel</p>
[15]	<p>Modelo Naïve</p> <p>Modelo autorregresivo de media móvil. ARMA</p> <p>Red neuronal con propagación hacia atrás. BP-NN</p> <p>Máquina de vectores de soporte con función de núcleo p-gaussiana</p> <p>Máquina de vectores de soporte con función de núcleo de base radial</p> <p>Máquina de vectores de soporte con función de núcleo polinomio</p> <p>Máquina de vectores de soporte con función de núcleo hiperbólica</p> <p>Máquina de vectores de soporte con función de núcleo de Laplace</p> <p>Máquina de vectores de soporte con función de núcleo de Bessel</p> <p>Máquina de vectores de soporte con función de núcleo lineal</p>
[9]	<p>Red neuronal con mínimos cuadrados y Máquina de vectores de soporte. RBF-LS-SVM</p> <p>Modelo autorregresivo. AR</p> <p>Modelo no paramétrico. NonPar</p> <p>Modelo autoregresivo con variable exógena. ARX</p> <p>Estrategia de comprar y retener. BUY-AND-HOLD (B&H)</p>
[44]	Fase de test
[3]	<p>Máquina de vectores de soporte con función de núcleo lineal</p> <p>Máquina de vectores de soporte con función de núcleo polinomio</p> <p>Máquina de vectores de soporte con función de núcleo de base radial</p> <p>Máquina de vectores de soporte con función de núcleo sigmoidea</p>
[35]	<p>Modelo multifractal de Markov-Switching. MSM</p> <p>Modelo de heterocedasticidad condicional autorregresiva no lineal generalizada. GARCH</p>
[39]	<p>Red neuronal. NN</p> <p>Promedio móvil</p> <p>Regresión MSE</p> <p>Modelo de base de varianza de pesos</p>
[34]	<p>Aprendizaje de múltiples núcleos con información de nuevos precios. MKL-NP</p> <p>Aprendizaje de múltiples núcleos con información de nuevos precios y volumen de transacción. MKL-NPV</p>
[63]	Núcleo de Aprendizaje
[23]	<p>Red neuronal con propagación hacia atrás. BP-NN</p> <p>Mínimos cuadrados y máquinas de vectores de soporte. LSSVM</p>
[38]	Red neuronal de propagación hacia adelante. FBP NN

Cita	Modelo de comparación
[36]	Aproximación Adaptativa Constante a Trozos y máquinas de vectores de soporte para regresión. PLR-SVR-RBF Aproximación Adaptativa Constante a Trozos y red neuronal con propagación hacia atrás. PLR-BPN
[25]	Modelo Elman Red neuronal de regresión generalizada. GRNN Red neuronal con transformada ondícula. WNN Promedio Simple Máquina de vectores de soporte. SVM
[51]	Modelo de corrección de Errores de Vectores Cointegrados. VECM Perceptrón multicapa por intervalos. iMLP Método de suavización exponencial de Holt para los intervalos. HoltI Máquina de vectores de soporte. SVM Algoritmo de optimización por enjambre de partículas con múltiples salidas y máquinas de vectores de soporte para regresión. PSO-MSVR Algoritmo genético con múltiples salidas y máquinas de vectores de soporte para regresión. GA-MSVR
[53]	Máquina de vectores de soporte para regresión. SVR Regularización por mínimos cuadrados difusos. RLF-SVR
[58]	No comparan contra un modelo
[2]	Proyecciones preservadoras de locales y máquinas de vectores de soporte. LPP+SVM Proyecciones locales preservadoras y red neuronal de propagación hacia adelante. LPP+RBFN Análisis de componentes principales y red neuronal de propagación hacia adelante. PCA+RBFN Proyecciones locales preservadoras y red neuronal. LPP+NN Análisis de componentes principales y red neuronal. PCA+NN Análisis de componentes principales con algoritmo de optimización por enjambre de partículas y máquinas de vectores de soporte. PCA+PSOSVM

5.7 ¿Cuáles medidas de ajuste han sido utilizadas para medir la precisión de los modelos?

A continuación se relacionan los estadísticos de ajuste usados para evaluar la precisión del pronóstico.

- Error cuadrático medio o su raíz, [2] [4] [5] [6] [7] [9] [10] [37] [41] [43] [44] [48] [49] [53] [57] [58] [59] [63] [65] [66] [67] [68] [69] [70] [71] [72] [73] [76].
- Error cuadrático medio normalizado [2] [12] [13] [23] [41] [42] [43] [52] [55] [56] [63] [64] [66] [74] [77].
- Error medio absoluto [4] [5] [12] [37] [43] [48] [52] [55] [71] [63] [64] [65] [68] [72].
- Error porcentual absoluto medio [2] [7] [13] [36] [37] [38] [39] [41] [44] [53] [65] [68] [70] [71].

- Cambio de dirección [2] [7] [9] [13] [36] [37] [38] [39] [41] [44] [45] [46] [48] [53] [65] [68] [70] [71].
- Coeficiente de correlación [6] [7] [10] [45].
- Error medio relativo [2] [41].

5.8 ¿Cuáles son las principales conclusiones a las que llegaron los investigadores en la literatura revisada?

De 59 documentos analizados, la conclusión más frecuente a la que llegaron los investigadores, es que los modelos SVM son mejores modelos pronosticadores comparados con modelos econométricos y modelos de inteligencia artificial como las redes neuronales artificiales. Sin embargo, los modelos de SVM que incluyen algún tipo de mejora sobre en el tratamiento de los datos [9] [65], la arquitectura tradicional [37] [55] [63], el método para estimar los parámetros óptimos del modelo [38] [39] [44] [61] o la combinación con otro modelo [5] llevan a una ganancia en la precisión del pronóstico.

El problema con los estudios encontrados en relación a sus conclusiones es que no hay una base común de pruebas para la comparación entre modelos, de tal forma que no es posible decir si dos modelos producen resultados estadísticamente diferentes y cual es mejor que otro. En este sentido, es necesario realizar investigaciones orientadas a la comparación entre modelos sobre una misma base experimental con el fin de determinar que técnicas son consistentemente más precisas y bajo que condiciones.

El resumen de las principales conclusiones dadas por los autores se presenta en la Tabla 9.

Tabla 9. Principales conclusiones reportadas en la literatura seleccionada

Cita	Principales Conclusiones
[22]	El estudio concluye que SVM provee una alternativa promisoría en el pronóstico de series de tiempo financieras.
[7]	SVM tiene una buena perspectiva para predecir algunas variables el mercado de valores
[37]	La medida de ajuste NMSE y MAE revelan los valores más bajos, mostrando la mejor capacidad predictiva del modelo SVM con respecto a la BPNN
[40]	El resultado muestra que ASVM y WBP pueden pronosticar mejor los valores reales de RDP-5 que sus correspondientes métodos estándar SVM y RB
[54]	En el documento se investigó el uso de diferentes métodos, incluyendo SVM, NN y SMA, para predecir los tipos de cambio de las monedas ADD, EDR y CHF contra Dólar USD. Los resultados de la simulación muestran SVM puede pronosticar mejor las monedas que componen el portafolio de inversión.
[18]	QM-ASVR/NGARCH demostró tener una mayor precisión en el pronóstico de series de tiempo financieras GM, ARMA, RBFNN, ANFIS, SVR y RGA-ASVR/NGARCG

Cita	Principales Conclusiones
[31]	El método basado en SVM ha demostrado ser una herramienta poderosa para pronosticar las series de tiempo, mediante el uso de algunas técnicas de selección de características, por ejemplo, la incorporación de los indicadores técnicos empíricos.
[17]	Los resultados experimentales muestran que el modelo propuesto EMD-SVR son superiores a los modelos de comparación AR(1) y SVR de acuerdo con el valor de RMSE obetnido.
[24]	El MAPE más pequeño lo muestra el modelo SVR-CPSO, mientras que el MAPE más alto lo presentó el modelo ARIMA mostrando la superioridad del modelo propuesto para pronosticar el SSE.
[5]	Los resultados demostraron que SVR + GHSOM alcanza resultados significativos cuando se pronostican valores intradía
[45]	El artículo muestra que la SVM-KM puede tener un mejor desempeño en el pronóstico y que no necesariamente el uso de la correlación cruzada mejora el pronóstico de las series de tiempo financieras.
[29]	El experimento demostró que ambos modelos SVR y BP obtienen mejores resultados que los modelos ARMA-GARCH y ARMA de acuerdo con el criterio de medición de la desviación estándar. Sin embargo, en los criterios de pronóstico de dirección, los modelos ARMA-GARCH superan los modelos SVR y BP.
[55]	Una arquitectura en dos etapas, mejora el desempeño del modelo SVM
[56]	El experimento demostró, con el MAE más bajo, que el WSVM es el mejor pronosticador.
[59]	El SOFM-SVR superó significativamente la tradicional SVR en el pronóstico de la serie de tiempo según la prueba Wilcoxon
[8]	En comparación con las NN, SVM-NN funcionan mejor. El RMSE se reduce significativamente.
[13]	Los resultados indican que el modelo SVRCACO ofrece resultados más precisos de los pronósticos que los modelos HSVMG, NN, VLLR y RW.
[16]	El método SVR tiene un mejor desempeño que MLP y GARCH
[42]	Los resultados mostraron que el desempeño de una técnica de pronóstico depende de la estrategia de negociación.
[27]	La Ecuación de Kernel tiene gran impacto en los resultados de optimización de SVM. El resultado del experimento muestra que modelo compuesto puede lograr un pronóstico más preciso.
[6]	GMRVvm-SVR puede utilizarse para resolver problemas de pronóstico. Sin embargo, el efecto de predicción del modelo no siempre es satisfactorio.
[26]	Los resultados experimentales demuestran que el LG-SVR puede mejorar la precisión del pronóstico y acelerar el cálculo en los datos de muestra de tamaño mediano y grande.
[43]	Con el modelo Wavelet -MARS-SVR se pronosticó el índice SSEC de China, el índice Bovespa de Brasil, el índice DowJones de Estados Unidos y Nikkei 225 Índice de Japón. Por otra parte, se pronosticaron estas mismas series de tiempo con los modelos ANFIS, Wavelet-SVR, Wavelet-MARS, ARIMA y SVR usando el error de predicción como criterio. Los resultados empíricos muestran que el modelo propuesto tiene el menor error de predicción comparado con los cinco modelos anteriores.
[12]	En resumen, el modelo SVR-CFA es más adecuado que los otros tres métodos para describir la relación entre los datos de entrada y de salida
[1]	Los resultados mostraron que el concepto de correlación y el GA ayudan a mejorar el rendimiento del sistema de SVM significativamente.
[52]	La RLF-SVR presenta un mejor rendimiento que el modelo SVM tradicional
[50]	Los resultados experimentales mostraron que SVM superó el modelo BPN y el modelo CBR.
[60]	SVM funciona bien en el pronóstico a corto plazo de las series financieras.
[46]	Los resultados experimentales sobre tres índices indican que el algoritmo AWSVR propuesto tiene mejor desempeño en la predicción que SVR.

Cita	Principales Conclusiones
[49]	Se puede concluir que el modelo propuesto EMD-SVR es una herramienta efectiva para el pronóstico de series de tiempo financieras.
[61]	En el documento se consigue que la tendencia del índice compuesto de la Bolsa de Shanghai quincenal obtenido sea muy cercano a la realidad
[14]	Estos resultados muestran que la que la técnica de modelado no lineal propuesto es un enfoque muy prometedor para el pronóstico de series de tiempo financieras.
[11]	El modelo eABC-LSSVM muestra una ejecución satisfactoria en el error MAPE y PA para cuantificar de manera adecuada σ y γ que un modelo LSSVM.
[28]	El pronóstico de la variable de salida muestra que el uso de eABC es mejor solución que ABC y que CV para hallar los parámetros de LSSVM, particularmente para predecir el precio del oro.
[20]	El modelo SVM supera el modelo BPN en esta investigación.
[57]	El resultado experimental mostró que el modelo lp-norm MK-SVR tiene una mejor desempeño que el modelo SKSVR
[62]	El NDEM muestra el mejor rendimiento en el pronóstico de una SVM para clasificación de tendencia.
[19]	Se considera que el Kernel Wavelet Spline se desempeña mejor que el kernel de Gauss.
[32]	Las predicciones hechas con el nucleo kernel wavelet son mejores que kernel gaussiana
[21]	El experimento demuestra que el GARCH-SWSVM pronostica significativamente mejor que el Gaussian kernel-SVM.
[33]	El tipo de cambio Santa Fe y cinco tasas de interés de contratos de futuros utilizados en el experimento, mostraron que el método propuesto tiene una capacidad de pronóstico del rendimiento significativamente mayor y una velocidad de convergencia más rápida que lo obtenido con un modelo SVM sencillo.
[41]	El e-DSVMs demuestra un mejor desempeño en el pronóstico de series de tiempo financieras que el SVM estándar
[4]	Las pruebas estadísticas que muestran los resultados de la evaluación en el caso de la moneda EUR / GBP confirman un buen desempeño del modelo Hiperbólico SVM, Laplace SVM y RBF SVM. En el caso de la mondea EUR/USD el mejor desempeño fue del modelo P.Gaussian SVM y para EUR/JPY fue el Hiperbólico SVM.
[15]	SVM son un sistema prometedor de aprendizaje para hacer frente a las tareas de clasificación no lineales, en el campo del pronóstico de las series de tiempo financieras.
[9]	El RBF-LS-SVM, se comporta mejor que el resto de modelos con respecto al criterio de precisión direccional de acuerdo al P-Value obtenido
[44]	El método se aplicó en la predicción del DAX30 y los resultados se muestran significativos en cuanto a la exactitud de la dirección del precio, los coeficientes de correlación y su capacidad de sincronización con el Mercado
[3]	Los resultados experimentales muestran que el método de descomposición en valores singulares (SVD) con el algoritmo C-C y modelo Caos-SVM pueden lograr buenos resultados en la predicción de regresión.
[35]	El modelo SVM-MSM demostró un mejor desempeño que el modelo GARCH
[39]	El desempeño y capacidad de pronóstico del RBF para SVM es mejor desde la medida NMSE
[34]	Múltiples métodos de aprendizaje con kernel tienen un índice de exactitud más alta y una tasa menor de predicción falsa en comparación con los métodos individuales de núcleo
[63]	El método SVR-RBK se aplicó en el pronóstico del Indices Financieros S&P500 y el NASDAQ y mostro resultados prometedores con respecto a Procedimiento Two-step y Aprendizaje de Kernel.
[23]	Cuando LS-SVM es optimizado con un W-PSO, se logra el mejor resultado.
[38]	Se demuestra que SVM es significativamente mejor pronosticador que Feed-Forward BP-NN

Cita	Principales Conclusiones
[36]	Los resultados experimentales muestran que el modelo propuesto TBSM-SVR puede generar más beneficios que otros modelos como PLR-SVR y PLR-BPN de acuerdo con el RMSE obtenido
[25]	Mediante el ingreso de datos diarios a los modelos Elman, GRNN and WNN y al comparar los resultados de predicción, se encontró que, en general, la tasa de rendimiento anual del obtenida con el modelo de conjunto no lineal propuesto NNSVM es mejor que los modelos de una sola base y los modelos por conjuntos lineales para pronosticar los índices bursátiles con alta volatilidad y el ruido.
[51]	Los resultados obtenidos en el estudio indican que el modelo propuesto FA-MSVR es una alternativa promisoría para predecir el valor del intervalo de la series de tiempo
[53]	El modelo LSVR demostró tener el menor MSE al pronosticar tres indicadores técnicos los otros modelos propuestos.
[58]	El modelo de pronóstico PS-SVM mostró ser más efectivo y potente Algoritmos BFGS
[2]	Los resultados experimentales muestran que el modelo propuesto LPP+PSOSVM se comporta mejor que otros modelos en la predicción de los rendimientos.

6 CONCLUSIONES

Las principales conclusiones alcanzadas en esta investigación se resumen en los siguientes puntos:

- Existe una clara preferencia por usar la función de base radial para especificar el kernel de la SVM, aunque en nuestro conocimiento no hay razones teóricas o conceptuales para descartar otros tipos de función kernel. Sobre este punto se deben desarrollar más investigaciones.
- Prevalece el uso de la función ε -insensible para especificar la función de pérdida en las SVM, aunque ello implique tener que buscar los valores óptimos de C y ε , lo cual suele ser un problema complejo. En este sentido, no hay estudios que indiquen con conclusiones contundentes si sería mejor usar otra función de error.
- En relación al punto anterior, ha venido ganando popularidad el uso de técnicas heurísticas de optimización para la estimación de los parámetros óptimos de la SVM, tales como los algoritmos genéticos y los enjambres de partículas.
- La mayor parte de la investigación está orientada a obtener mejores pronósticos de los valores diarios futuros de los índices financieros de las bolsas de valores, y en mejor grado al pronóstico de los precios de acciones individuales. Un hallazgo contrario a la intuición de los autores, es que hay poco interés en el pronóstico de las tasas de cambio con SVMs.
- La precisión del pronóstico puede ser mejorada no solamente al considerar algún tipo de cambio en la SVM; diversos estudios demuestran que la combinación con indicadores técnicos como la media móvil, el índice MACD o el índice de fuerza relativa pueden mejorar ostensiblemente la precisión del pronóstico.
- Las SVM son comparadas comúnmente contra su versión más clásica o contra otros modelos de redes neuronales o redes neurodifusas, y en menor medida contra otras técnicas estadísticas como los modelos ARIMA.
- No existe una base sólida de casos de comparación que permita llegar a conclusiones generales sobre qué tipos de mejoras introducidas a las SVM producen mejores resultados en términos de precisión del pronóstico.

REFERENCIAS

- [1] Abu-Mostafa, Y. S., & Atiya, A. F. (1996). Introduction to financial forecasting. *Applied Intelligence*, 6(3), 205-213.
- [2] H. Jiang and Z. Wang, "GMRVVM-SVR model for financial time series forecasting," *Expert Syst. Appl.*, vol. 37, no. 12, pp. 7813-7818, Dec. 2010.
- [3] C. Cai, Q. Ma, and S. Lv, "Research on support vector regression in the stock market forecasting," *Adv. Intell. Soft Comput.*, vol. 148, pp. 607-612, 2012.
- [4] S.-C. Huang, P.-J. Chuang, C.-F. Wu, and H.-J. Lai, "Chaos-based support vector regressions for exchange rate forecasting," *Expert Syst. Appl.*, vol. 37, no. 12, pp. 8590-8598, Dec. 2010.
- [5] T. Van Gestel, J. K. Suykens, D. E. Baestaens, A. Lambrechts, G. Lanckriet, B. Vandaele, B. De Moor, and J. Vandewalle, "Financial time series prediction using least squares support vector machines within the evidence framework.," *IEEE Trans. Neural Netw.*, 2001.
- [6] B. Wang, H. Huang, and X. Wang, "A support vector machine based MSM model for financial short-term volatility forecasting," *Neural Comput. Appl.*, vol. 22, no. 1, pp. 21-28, Oct. 2011.
- [7] F. L. F. Luo, J. W. J. Wu, and K. Y. K. Yan, "A novel nonlinear combination model based on Support Vector Machine for stock market prediction," *Intell. Control Autom. (WCICA)*, 2010 8th World Congr., no. 200707, pp. 5048-5053, 2010.
- [8] V. Khatibi, E. Khatibi, and A. Rasouli, "A new support vector machine-genetic algorithm (SVM-GA) based method for stock market forecasting," *Int. J. Phys. Sci.*, vol. 6, no. 25, pp. 6091-6097, 2011.
- [9] G. Zhiqiang, W. Huaiqing, and L. Quan, "Financial time series forecasting using LPP and SVM optimized by PSO," *Soft Comput.*, vol. 17, no. 5, pp. 805-818, 2013.
- [10] C. E. N. Wan and S. Chai, "Research on The Prediction of Stock Market Based on Chaos and SVM," *WSEAS Trans. Inf. Sci. Appl.*, vol. 11, pp. 186-195, 2014.
- [11] C. Ullrich, D. Seese, and S. Chalup, "Predicting foreign exchange rate return directions with support vector machines," *Proc. 4th Australas. Data Min. Conf.*, 2005.
- [12] R. de Brito and A. Oliveira, "A foreign exchange market trading system by combining GHSOM and SVR," *WCCI 2012 IEEE World Congr. Comput. Intell.*, pp. 1-7, 2012.
- [13] Y. Cheng, Y. Fu, and G. Gong, "A Hybrid Support Vector Regression Based on Chaotic Particle Swarm Optimization Algorithm in Forecasting Financial Returns," *2010 2nd Int. Conf. Inf. Eng. Comput. Sci.*, no. 2, pp. 1-4, Dec. 2010.
- [14] A. Arango and J.D. Velásquez. "Forecasting the Colombian Exchange Market Index (IGBC) using Neural Networks". *IEEE Latin America Transactions*, 12 (4), pp. 718-724, 2014.
- [15] P.C. Chang, C.Y. Fan, A hybrid system integrating a wavelet and TSK fuzzy rules for stock price forecasting, *IEEE Transactions on Systems, Man, and Cybernetics-Part C: Applications and Reviews* 38 (6) (2008) 802-815.
- [16] G. S. Atsalakis and K. P. Valavanis, "Forecasting stock market short-term trends using a neuro-fuzzy based methodology", *Expert Systems with Applications*, vol. 36, no. 7, pp. 10696-10707, 2009.
- [17] Q. Wen, Z. Yang, Y. Song and P. Jia, "Automatic stock decision support system based on box theory and SVM algorithm", *Expert Systems with Applications*, vol. 37, no. 2, pp. 1015-1022, 2010.
- [18] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: Theory and applications," *Neurocomputing*, vol. 70, pp. 489-501, 2006.

- [19] G.S. Atsalakis, K.P. Valavanis, Surveying stock market forecasting techniques - Part II: Soft computing methods, *Expert Systems with Applications* 36 (3) (2009) 5932-5941.
- [20] A. Bahrammirzaee, A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems, *Neural Computing & Applications* 19 (8) (2010) 1165-1195.
- [21] V.N. Vapnik. "Statistical Learning Theory". Wiley, New York. 1998.
- [22] V.N. Vapnik. "The Nature of Statistical Learning Theory". Springer, N.Y. 1995.
- [23] W. Hung and W. Hong, "Application of SVR with improved ant colony optimization algorithms in exchange rate forecasting," *Control Cybern*, vol. 38, no. 3, pp. 863-891, 2009.
- [24] V.N. Vapnik, S.E. Golowich y A.J. Smola. "Support vector method for function approximation, regression estimation, and signal processing". *Advances in Neural Information Processing Systems*, Vol. 9, pp. 281-287. 1996.
- [25] C.J.C. Burges. "A tutorial on support vector machines for pattern recognition". *Data Mining and Knowledge Discovery*, Vol. 2, pp. 121- 167. 1998.
- [26] A.I. Belousov, S.A. Verzakov y J. Von Frese. "A flexible classification approach with optimal generalisation performance: support vector machines". *Chemometrics and Intelligent Laboratory Systems*, Vol. 64, pp. 15- 25. 2002.
- [27] A.J. Smola, y B. Scholkopf, "A tutorial on support vector regression". *NeuroCOLT Technical Report NC-TR-98-030*, Royal Holloway College, University of London, UK, 1998.
- [28] Cao, L. (2003). Support vector machines experts for time series forecasting. *Neurocomputing*, 51, 321-339.
- [29] S. Mukherjee, E. Osuna, y F. Girosi. "Nonlinear prediction of chaotic time series using support vector machines". *Proceedings of IEEE NNISP'97*, Amelia Island, FL, 1997.
- [30] K.R. Muller, A. Smola, G. Rätsch, B. Schölkopf, J. Kohlmorgen, y V.N. Vapnik. "Predicting time series with support vector machines", in: W. Gerstner, A. Germond, M. Hasler, J.-D. Nicoud (Eds.), *Proceedings of ICANN '97*, Springer LNCS 1327, Berlin, pp. 999- 1004. 1997.
- [31] S. Osowski and K. Garanty. "Forecasting of the daily meteorological pollution using wavelets and support vector machine". *Engineering Applications of Artificial Intelligence*, Vol. 20, pp. 745-755. 2007.
- [32] F.E.H Tay and L. Cao. "Application of support vector machines in financial time series forecasting". *Omega*, Vol. 29, pp. 309-317. 2001.
- [33] U. Thissen, R. van Brakel, A.P. de Weijer, W.J. Melssen, and L.M.C. Buydens. "Using vector support machines for time series prediction". *Chemometrics and Intelligent Laboratory Systems*, Vol. 69, pp. 35-49. 2003.
- [34] B. Scholkopf y A. Smola A. "Learning with Kernels". MIT Press, Cambridge, MA. 2002.
- [35] J.D. Velásquez, Y. Olaya, and C.J. Franco. "Time series prediction using vector support machines", *Ingeniare*, 18 (1), pp. 64-75. 2010.
- [36] W. Shen, Y. Zhang, and X. Ma, "Stock Return Forecast with LS-SVM and Particle Swarm Optimization," 2009 Int. Conf. Bus. Intell. Financ. Eng., pp. 143-147, Jul. 2009.
- [37] Y. Xiao, M. Xiao, and F. Zhao, "Improving Financial Returns Using Neural Networks and Adaptive Particle Swarm Optimization," 2012 Fifth Int. Conf. Bus. Intell. Financ. Eng., pp. 15-19, Aug. 2012.
- [38] Z. Mustafa and Y. Yusof, "A Hybridization of Enhanced Artificial Bee Colony-Least Squares Support Vector Machines for Price Forecasting," *J. Comput. Sci.*, vol. 8, no. 10, pp. 1680-1690, 2012.

- [39] Z. Mustafa and Y. Yusof, "LSSVM Parameters Tuning with Enhanced Artificial Bee Colony," *Int. Arab J. Inf. Technol.*, vol. 11, no. 3, pp. 236-242, 2014.
- [40] H. Jiang and W. He, "Grey relational grade in local support vector regression for financial time series prediction," *Expert Syst. Appl.*, vol. 39, no. 3, pp. 2256-2262, Feb. 2012.
- [41] J. Hui and W. Zhizhong, "Financial time series prediction based on grey model integrated with support vector regression," *Proc. 2009 IEEE Int. Conf. Grey Syst.*, pp. 570-576, 2009.
- [42] L.-B. Tang, H.-Y. Sheng, and L.-X. Tang, "GARCH prediction using spline wavelet support vector machine," *Neural Comput. Appl.*, vol. 18, no. 8, pp. 913-917, Feb. 2009.
- [43] A. Hossain and M. Nasser, "Comparison of the finite mixture of ARMA-GARCH, back propagation neural networks and support-vector machines in forecasting financial returns," *J. Appl. Stat.*, vol. 38, no. 3, pp. 533-551, Mar. 2011.
- [44] A. Kazem, E. Sharifi, F. K. Hussain, M. Saberi, and O. K. Hussain, "Support vector regression with chaos-based firefly algorithm for stock market price forecasting," *Appl. Soft Comput.*, vol. 13, no. 2, pp. 947-958, Feb. 2013.
- [45] P. Pai and W. Wei, "Predicting movement directions of stock index futures by support vector models with data preprocessing," *Ind. Eng. Eng. Manag. 2007 IEEE Int. Conf.*, no. 4, pp. 169-173, 2007.
- [46] F. Wang, L. Liu, and C. Dou, "Stock market volatility prediction: A service-oriented multi-kernel learning approach," *Proc. - 2012 IEEE 9th Int. Conf. Serv. Comput. SCC 2012*, vol. d, pp. 49-56, 2012.
- [47] J. Chen, "SVM APPLICATION OF FINANCIAL TIME SERIES FORECASTING USING EMPIRICAL TECHNICAL INDICATORS," *2010 Int. Conf. Information, Netw. Autom.*, pp. 77-81, 2010.
- [48] W. Q. Duan and H. E. Stanley, "Cross-correlation and the predictability of financial return series," *Phys. A Stat. Mech. its Appl.*, vol. 390, no. 2, pp. 290-296, Jan. 2010.
- [49] Z. Li, Y. Li, F. Yu, and D. Ge, "Adaptively Weighted Support Vector Regression for Financial Time Series Prediction," *Neural Networks (IJCNN)*, pp. 6-9, 2014.
- [50] L. Tang and H. Sheng, "Wavelet kernel function for stock index forecast," *2nd Int. Symp. Electron. Commer. Secur. ISECS 2009*, vol. 2, pp. 382-385, 2009.
- [51] F. E. H. Tay, F. E. H. Tay, L. J. Cao, and L. J. Cao, "Improved financial time series forecasting by combining support vector machines with self-organizing feature map," *Intelligent-Data-Analysis*, vol. 5, pp. 339-354, 2001.
- [52] L. Cao and F. Tay, "Support vector machine with adaptive parameters in financial time series forecasting," *Neural Networks, IEEE Trans.*, vol. 14, no. 6, pp. 1506-1518, 2003.
- [53] L. J. Kao, C. C. Chiu, C. J. Lu, and C. H. Chang, "A hybrid approach by integrating wavelet-based feature extraction with MARS and SVR for stock index forecasting," *Decis. Support Syst.*, vol. 54, no. 3, pp. 1228-1244, Feb. 2013.
- [54] K. Kim, "Financial time series forecasting using support vector machines," *Neurocomputing*, vol. 55, no. 1-2, pp. 307-319, Sep. 2003.
- [55] L. Cao and F. E. . Tay, "Financial Forecasting Using Support Vector Machines," *Neural Comput. Appl.*, vol. 10, no. 2, pp. 184-192, May 2001.
- [56] F. Tay and L. Cao, "e-descending support vector machines for financial time series forecasting," *Neural Process. Lett.*, pp. 179-195, 2002.
- [57] H. Ince, "Non-Parametric Regression Methods," *Comput. Manag. Sci.*, vol. 3, no. 2, pp. 161-174, Feb. 2006.

- [58] J.-L. Wu and P.-C. Chang, "A Trend-Based Segmentation Method and the Support Vector Regression for Financial Time Series Forecasting," *Math. Probl. Eng.*, vol. 2012, pp. 1-20, 2012.
- [59] H. Yang, K. Huang, I. King, and M. R. Lyu, "Localized support vector regression for time series prediction," *Neurocomputing*, vol. 72, no. 10-12, pp. 2659-2669, Jun. 2009.
- [60] Y. Yuan, "Forecasting the movement direction of exchange rate with polynomial smooth support vector machine," *Math. Comput. Model.*, vol. 57, no. 3-4, pp. 932-944, Feb. 2013.
- [61] T. Xiong, Y. Bao, and Z. Hu, "Multiple-output support vector regression with a firefly algorithm for interval-valued stock price index forecasting," *Knowledge-Based Syst.*, vol. 55, pp. 87-100, 2014.
- [62] C. Ullrich, D. Seese, and S. Chalup, "Foreign Exchange Trading with Support Vector Machines," *Adv. Data Anal.*, no. 2003, pp. 539-546, 2007.
- [63] L. Tang and H. Y. Sheng, "Forecasting stock returns based on spline wavelet support vector," *Proc. 2009 Int. Conf. Comput. Intell. Nat. Comput. CINC 2009*, no. 2, pp. 383-385, 2009.
- [64] Y. Bao, Y. Lu, and J. Zhang, "Forecasting stock price by SVMs regression," *Lect. Notes Artif. Intell. (Subseries Lect. Notes Comput. Sci.)*, pp. 295-303, 2004.
- [65] C.-S. Lin, S.-H. Chiu, and T.-Y. Lin, "Empirical mode decomposition-based least squares support vector regression for foreign exchange rate forecasting," *Econ. Model.*, vol. 29, no. 6, pp. 2583-2590, Nov. 2012.
- [66] D. Wang and Y. Li, "A novel nonlinear RBF neural network ensemble model for financial time series forecasting," *Third Int. Work. Adv. Comput. Intell.*, pp. 86-90, 2010.
- [67] H. Ince and T. B. Trafalis, "Short term forecasting with support vector machines and application to stock price prediction," *Int. J. Gen. Syst.*, vol. 37, no. 6, pp. 677-687, Dec. 2008.
- [68] C.-L. Huang and C.-Y. Tsai, "A hybrid SOFM-SVR with a filter-based feature selection for stock market forecasting," *Expert Syst. Appl.*, vol. 36, no. 2, pp. 1529-1539, Mar. 2009.
- [69] C. H. Cheng and L. Y. Wei, "A novel time-series model based on empirical mode decomposition for forecasting TAIEX," *Econ. Model.*, vol. 36, pp. 136-141, 2014.
- [70] L. Lai and J. N. K. Liu, "Stock forecasting using support vector machine," *Proc. Ninth Int. Conf. Mach. Learn. Cybern.*, no. July, pp. 11-14, 2010.
- [71] W. Chong and C. Pu, "Application of Support Vector Machines in Paying Rate Forecasting," *Manag. Sci. Eng. 2006. ICMSE '06. 2006 Int. Conf.*, pp. 1494-1497, 2006.
- [72] H. Chao, H. Li-li, and H. Ting-ting, "Financial time series forecasting based on wavelet kernel support vector machine," *2012 8th Int. Conf. Nat. Comput.*, vol. 2, no. Icncc, pp. 79-83, 2012.
- [73] X. Shao, K. Wu, and B. Liao, "p -Norm Multikernel Learning Approach for Stock Market Price Forecasting," *Comput. Intell. Neurosci.*, vol. 2012, 2012.
- [74] Y. C. Y. Cao, H. H. H. He, and R. Chandramouli, "A novel portfolio optimization method for foreign currency investment," *Neural Networks, 2009. Int. Jt. Conf. Neural Networks*, pp. 439-445, 2009.
- [75] S. Xue-shen, Q. Zhong-ying, Y. Da-ren, H. Qing-hua, and Z. Hui, "A novel feature selection approach using classification complexity for SVM of stock market trend prediction," *2007 Int. Conf. Manag. Sci. Eng.*, pp. 1654-1659, 2007.
- [76] B. R. C. B. R. Chang and H. F. T. H. F. Tsai, "Financial Prediction Applications Using Quantum-Minimized Composite Model ASVR/NGARCH," *2006 IEEE Int. Jt. Conf. Neural Netw. Proc.*, pp. 1247-1253, 2006.
- [77] R. Khemchandani and S. Chandra, "Regularized least squares fuzzy support vector regression for financial time series forecasting," *Expert Syst. Appl.*, vol. 36, no. 1, pp. 132-138, Jan. 2009.

- [78] T. Van Gestel, J. Suykens, B. De Moor, and D.-E. Baestaens, "Volatility tube Support Vector Machines," *Neural Netw. World*, vol. 10, no. 1, pp. 287-297, 2000.
- [79] S.-H. Hsu, J. P.-A. Hsieh, T.-C. Chih, and K.-C. Hsu, "A two-stage architecture for stock price forecasting by integrating self-organizing map and support vector regression," *Expert Syst. Appl.*, vol. 36, no. 4, pp. 7947-7951, May 2009.
- [80] L. Wang and J. Zhu, "Financial market forecasting using a two-step kernel learning method for the support vector regression," *Ann. Oper. Res.*, vol. 174, no. 1, pp. 103-120, May 2008.
- [81] J. Lin and J. Sun, "The Prediction of Stock Index Based on Fuzzy Wavelet Analysis," 2007 *Int. Conf. Wirel. Commun. Netw. Mob. Comput.*, pp. 6380-6383, Sep. 2007.