



Tecnura

ISSN: 0123-921X

tecnura.ud@correo.udistrital.edu.co

Universidad Distrital Francisco José de  
Caldas  
Colombia

Jara Estupiñan, Jefferson; Giral, Diego; Martínez Santa, Fernando  
Implementación de algoritmos basados en máquinas de soporte vectorial (SVM) para  
sistemas eléctricos: revisión de tema  
Tecnura, vol. 20, núm. 48, abril-junio, 2016, pp. 149-170  
Universidad Distrital Francisco José de Caldas  
Bogotá, Colombia

Disponible en: <http://www.redalyc.org/articulo.oa?id=257046835012>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica  
Red de Revistas Científicas de América Latina, el Caribe, España y Portugal  
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto



## Implementación de algoritmos basados en máquinas de soporte vectorial (SVM) para sistemas eléctricos: revisión de tema

### Implementation of algorithms based on support vector machine (SVM) for electric systems: topic review

Jefferson Jara Estupiñán<sup>1</sup>, Diego Giral<sup>2</sup>, Fernando Martínez Santa<sup>3</sup>

**Fecha de recepción:** 10 de enero de 2016

**Fecha de aceptación:** 15 de febrero de 2016

**Cómo citar:** Jara Estupiñán, J., Giral, D., & Martínez Santa, F. (2016). Implementación de algoritmos basados en máquinas de soporte vectorial (SVM) para sistemas eléctricos: revisión de tema. *Revista Tecnura*, 20(48), 149-170. doi: 10.14483/udistrital.jour.tecnura.2016.2.a11

#### Resumen

**Objetivo:** Realizar una revisión sobre la implementación de algoritmos basados en máquinas de soporte vectorial para sistemas eléctricos.

**Método:** Se realiza una búsqueda de artículos principalmente en Índices bibliográficos (IB) y Bases Bibliográficas con Comité de Selección (BBSC) acerca de las máquinas de soporte vectorial.

Este trabajo presenta una descripción cualitativa y/o cuantitativa acerca de los avances y aplicaciones en el entorno eléctrico, abordando temas como: predicción del mercado eléctrico, predicción de la demanda, pérdidas no técnicas de electricidad (hurto), energías alternativas, transformadores, entre otros; en cada trabajo se realiza la respectiva citación con el fin de garantizar los derechos de autor y permitirle al lector el movimiento dinámico entre lo consignado en este trabajo y los trabajos citados.

**Resultados:** Se realiza la revisión de una manera detallada, centrando la búsqueda en algoritmos

implementados en sistemas eléctricos y en áreas de aplicación novedosas.

**Conclusión:** Las máquinas de soporte vectorial tienen bastantes aplicaciones debido a sus múltiples beneficios, sin embargo en el área de energía eléctrica, estas no se han aplicado en su totalidad, esto permite identificar un área prometedora de trabajos de investigación.

**Palabras clave:** Algoritmos, aprendizaje de máquina, máquinas de soporte vectorial, electricidad.

#### Abstract

**Objective:** To perform a review of implementation of algorithms based on support vector machine applied to electric systems.

**Method:** A paper search is done mainly on Bibliographic Indexes (BI) and Bibliographic Bases with Selection Committee (BBSC) about support vector machine. This work shows a qualitative and/or quantitative description about advances and applications

1 Estudiante de tecnología en electricidad. Universidad Distrital Francisco José De Caldas, Bogotá, Colombia. Contacto: [jjarae@correo.udistrital.edu.co](mailto:jjarae@correo.udistrital.edu.co)

2 Ingeniero eléctrico, Magister en Ingeniería Eléctrica. Docente Universidad Distrital Francisco José De Caldas, Bogotá, Colombia. Contacto: [dagiralr@udistrital.edu.co](mailto:dagiralr@udistrital.edu.co)

3 Ingeniero electrónico, magister en Ingeniería Electrónica y de Computadores. Docente de la Universidad Distrital Francisco José de Caldas, Bogotá, Colombia. Contacto: [fmartinezs@udistrital.edu.co](mailto:fmartinezs@udistrital.edu.co)

in the electrical environment, approaching topics such as: electrical market prediction, demand prediction, non-technical losses (theft), alternative energy source and transformers, among others, in each work the respective citation is done in order to guarantee the copy right and allow to the reader a dynamic movement between the reading and the cited works.

**Results:** A detailed review is done, focused on the searching of implemented algorithms in electric systems and innovating application areas.

**Conclusion:** Support vector machines have a lot of applications due to their multiple benefits, however in the electric energy area; they have not been totally applied, this allow to identify a promising area of researching.

**Keywords:** Algorithms, machine learning, support vector machines, electricity.

## INTRODUCCIÓN

Actualmente la inteligencia artificial ha tomado una gran fuerza y aceptación a nivel tanto industrial como residencial, debido a que muchas de sus aplicaciones ayudan o apoyan al ser humano en sus actividades diarias tanto las cotidianas como laborales; algunas aplicaciones de la inteligencia artificial son : Lingüística computacional ,Minería de datos (Data Mining), Industriales, Medicina, Mundos virtuales, Procesamiento (Natural Language Processing), Robótica, Mecatrónica, Sistemas de apoyo a la decisión, Videojuegos, Prototipos informáticos y Análisis de sistemas dinámicos, entre otros.

Basada en algoritmos de computación , lógica y matemática ; es una herramienta tan densa y útil ,que ha sido clasificada en varios campos , en este artículo el de interés sera las machine learning o (máquinas de aprendizaje) las cuales son una rama de la inteligencia artificial , y tienen como objeto el desarrollo de técnicas y procesos que permitan que una computadora o un algoritmo computacional sea capaz de aprender ; dicho de otra manera que sea capaz de generalizar una idea a partir de ejemplos que le son suministrados ; y así lograr predecir , clasificar y pronosticar; el comportamiento de un sistema.

En 1959, Arthur L. Samuel define el aprendizaje de máquina como un “campo de estudio que da a

las computadoras la capacidad de aprender sin ser programada de forma explícita “; su entrenamiento con bases de datos y ejemplos adecuados, ayuda a la máquina de aprendizaje a ser más precisa y eficiente en su labor , son sumamente utilices debido a su capacidad de aprendizaje; lo cual genera que en ocasiones encuentre soluciones que no se habían programado en el sistema, es decir que el sistema de datos puede ser variable y aun así, si la máquina de aprendizaje tuvo un buen entrenamiento será capaz de analizar, predecir y solucionar el problema que se le presente.

Son tan variadas y versátiles sus aplicaciones que lo encontramos incluso en el simple hecho de ver una película online, como es el caso de la plataforma virtual Netflix la cual utiliza el aprendizaje automático para dar a sus usuarios sugerencias de las películas que posiblemente le interesen, basándose en las programadas anteriormente.

Otra de las aplicaciones más renombradas del aprendizaje automático, son los automóviles no tripulados de google, los cuales basan parte de su funcionamiento en esta rama de la inteligencia artificial.

Las máquinas de aprendizaje se clasifican según su enfoque, de la siguiente manera:

1. Árboles de decisiones
2. Reglas de asociación
3. Algoritmos genéticos
4. Redes neurales artificiales

5. Máquinas de vectores de soporte
6. Algoritmos de agrupamiento
7. Redes bayesianas

Algunas de las más utilizadas a nivel mundial serán descritas brevemente a continuación:

**Árboles de decisiones:** Son un modelo de predicción el cual a partir de una serie de datos puede categorizar y representar una serie de condiciones sucesivas, para la resolución de un problema en particular. Son herramientas excelentes para ayudar a realizar elecciones adecuadas entre muchas posibilidades. Su estructura permite seleccionar una y otra vez diferentes opciones para explorar las diferentes alternativas posibles de decisión.

Los árboles de decisión generalmente son binarios, es decir que cuentan con dos opciones, aunque esto no significa que no puedan existir árboles de tres o más opciones.

Su representación está dada en forma de árbol como su nombre lo indica seguido varios nodos cuadrados los cuales representan los puntos de decisión, de los cuales se emergen ramas las cuales representan las diferentes posibilidades o alternativas.

**Reglas de asociación:** Las reglas de asociación son utilizadas para predicción en procesos en los cuales una condición final depende de otras anteriores, es decir qué serie de cosas deben suceder para que una condición X se cumpla a cabalidad.

*‘La ventaja de los algoritmos de reglas de asociación sobre los algoritmos más estándar de árboles de decisión (C5.0 y Árbol C&R) es que las asociaciones pueden existir entre cualquiera de los atributos. Un algoritmo de árbol de decisión generará reglas con una única conclusión, mientras que los algoritmos de asociación tratan de buscar muchas reglas, cada una de las cuales puede tener una conclusión diferente.’* ( IBM Knowledge Center)

Es bastante utilizada en el área de marketing en cuanto a las compras de los consumidores como por ejemplo la persona que compra el producto Y, tiene una alta probabilidad de adquirir de igual manera el producto Z; de esta manera el propietario

del establecimiento decide que productos deben estar a una distancia menor del otro, con el fin de aumentar sus ventas.

Es también utilizado en varios procesos industriales en los cuales se pretende predecir qué sucederá a partir de una serie de acciones anteriores.

**Redes neuronales artificiales:** Este sistema lo que busca es simular el cerebro humano, las redes neuronales cuentan con elementos que asemejan una neurona biológica, los cuales procesan la información y son capaces de aprender de la experiencia, generalizar de ejemplos previos a ejemplos nuevos y abstraer la información más importante de una base de datos; siendo así de gran utilidad en múltiples procesos en los cuales se tenga una serie de datos óptimos para la utilización en la red neuronal artificial.

Algunas de sus aplicaciones son:


1. Reconocimiento de textos manuscritos
2. Reconocimiento del habla
3. Simulación de centrales de producción de energía
4. Detección de explosivos
5. Identificación de blancos de radares
6. En sistemas de energía eléctrica (varios campos).

Siendo de nuestro interés las máquinas de soporte vectorial del inglés support vector machine (SVM) pertenecientes a las máquinas de aprendizaje y contenidas en la inteligencia artificial, específicamente en el área de electricidad.

La energía eléctrica a través del tiempo se ha convertido en una parte muy importante de la vida cotidiana y día tras día aumenta dicha importancia, debido a que la mayoría del tiempo se interactúa directa o indirectamente con ella. Hoy la electricidad está presente tanto en un teléfono móvil como en las más altas tecnologías en el área de medicina; se ha hecho tan necesaria que es difícil el pensar en un solo día sin ella en nuestra vida moderna. Por esta razón, constantemente se utilizan nuevos métodos y tecnologías aplicadas a diferentes ramas de la energía, como mercado

eléctrico, calidad de potencia, análisis de pérdidas, entre otras, con el fin de mejorar u optimizar procesos o sistemas específicos. Muchos de estos métodos se basan en algoritmos bioinspirados o de inteligencia, como redes neuronales, algoritmos genéticos, filtros de Kalman y máquinas de soporte vectorial (SVM), entre otros. En el presente artículo se hace una recopilación de diferentes implementaciones de máquinas de soporte vectorial aplicadas a diferentes áreas de la electricidad.

La máquina de soporte vectorial, está basada en algoritmos que aprenden a partir de una serie de datos o muestras estocásticas de algún sistema a clasificar y en otras ocasiones, a predecir su comportamiento en un futuro, ya sea a corto, mediano o largo plazo (Betancour, 2005). Su alto nivel de clasificación traza un plano que divide (*frontera de decisión*, la cual debe ser lo más amplia posible) y clasifica los diferentes datos que se le han dado al algoritmo; si los datos no pueden ser clasificados de esta manera y en la frontera entre las clasificación quedan datos por clasificar, la SMV está en la capacidad de llevar los datos a un plano en  $R^n$  y buscar un hiperplano que divida y clasifique de manera correcta los datos. Este hiperplano crea una frontera lo más amplia posible entre los datos a clasificar (Betancour, 2005) como se ve en la figura 1.



**Figura 1.** Frontera o hiperplano entre los datos a clasificar

**Fuente:** Betancour (2005).

La SVM basa su funcionamiento en un espacio de hipótesis de funciones; el cambio de dimensión es inducido por un kernel que, básicamente, cumple la función de elevar a una mayor dimensión las características dadas (Resendiz, 2006), una de las maneras más comunes en que las SVM aprenden es mapeando las entradas  $X$  y pasándolas a un espacio de características, en el cual son mucho más sencillas de clasificar.

Para ampliar la información acerca de los principios matemáticos básicos de las SVM, se recomienda al lector direccionarse a los textos guías en el tema de este artículo como son: Betancour (2005); Resendiz (2006); Yucheng y Yubin (2010); Goddard, Gerardo, Silva y Ángel (2000); Luo, Hall, Goldgof y Remsen (2005); Qu, Oussar, Dreyfus y Xu (2009). Cabe aclarar que el procedimiento anteriormente descrito no es el único utilizado en las SVM; por el contrario, en cada una de las investigaciones el procedimiento y herramientas matemáticas para ello pueden cambiar parcial o totalmente.

De este poder de clasificación, de su facilidad de aprender y, por tanto, predecir acciones o sucesos, es que las SVM están siendo altamente utilizadas en los sistemas eléctricos, algunas aplicaciones serán mencionadas a continuación.

## PREDICCIÓN DEL MERCADO ELÉCTRICO

El mercado eléctrico es uno de los más variables ya que casi a diario el costo de la electricidad fluctúa, abriendo todo un campo de investigación con el fin de lograr predecir qué comportamiento tendrá el mercado, a corto, mediano o largo plazo, según se necesite.

En Italia (2007) se plantea que algunos de los factores que se estudian para la caracterización del mercado son: la carga, el tipo de día y la hora. Gao, Bompard, Napoli y Cheng (2007) los llaman los *insumos para el modelo flexible de previsión* (RVS), y plantean que existen básicamente dos métodos para analizar el mercado eléctrico: un análisis completo y detallado, y otro que tiene su base

en modelos matemáticos como las SVM que tratan de asociar y determinar una relación entre las entradas que se le dan al sistema (conocidas) y el costo de la electricidad. Sugieren, además, una serie de acciones y ecuaciones con las cuales logran predecir el costo, minimizando el margen de error y apoyándose en las SVM. La predicción de precios a corto plazo es algo compleja, puesto los datos son muy cambiantes, y hay variaciones muy drásticas en el costo de la energía. En la figura 2 se expone esta diferencia en el mercado italiano, a diferentes niveles de carga partiendo de la carga máxima (F1) y terminando en la carga base (F4).

A largo plazo Gao, Bompard, Napoli y Cheng (2007) utilizan las variaciones de oferta y demanda y el índice de concentración del mercado; en su investigación plantean no hacer la predicción en un momento específico sino algo más general. Por último, comparan y analizan las divergencias entre los diferentes métodos matemáticos utilizados para la predicción de mercado dando como conclusión que las SVM son útiles en este proceso, pero generan un error más alto en comparación con otros métodos.

La predicción del mercado eléctrico es una de las aplicaciones más estudiadas y practicadas


a partir de las SVM a nivel mundial, por ello en la tabla 1 se resumen los trabajos encontrados respecto al tema, con el fin de no incurrir en un tema tan estudiado y permitiéndole al lector redirigirse a estos trabajos si así lo desea.

## PREDICCIÓN DE LA DEMANDA Y CONSUMO DE ELECTRICIDAD

La demanda de electricidad es un tema bastante relevante, ya que con base en ella los generadores diseñan y planean su participación en el mercado; además de ser uno de los estudios que permite tener una mayor confiabilidad en el sistema eléctrico ayudando con uno de los principales retos del sistema: satisfacer de manera correcta y en su totalidad la demanda energética (Osman, Awad y Mahmoud, 2009).

Este es otro de los ámbitos en los cuales más se ha implementado el método de las SVM, por ende se representan en la tabla 2 los trabajos más relevantes encontrados en la investigación y recolección de información.

## CALIDAD DE POTENCIA ELÉCTRICA



**Figura 2.** Variación del precio de la energía en las diferentes clasificaciones en el mercado italiano

**Fuente:** Gao, Bompard, Napoli y Cheng (2007).

**Tabla 1.** Trabajos o investigaciones en el mercado eléctrico usando SVM

Fecha de publicación	Título del artículo o investigación	Nombre de los autores	Referencia bibliográfica
2009	Support vector machines (SVM) based short term electricity load-price forecasting	Swief, R. a. Hegazy, Y. G. Abdel-Salam, T. S. Bader, M.a	(Swief, Hegazy, Abdel-Salam, & Bader, 2009)
2009	Electricity Price Forecasting Based on Support Vector Machine Trained by Genetic Algorithm	Yan-Gao, Chen Yan-Gao Chen Guangwen, Ma Guangwen Ma	(Yan-Gao & Guangwen, 2009)
2010	Short-term electricity prices forecasting based on support vector regression and Auto-regressive integrated moving average modeling	Che, Jinxing Wang, Jianzhou	(Che & Wang, 2010)
2011	Day-ahead electricity price forecasting based on rolling time series and least square-support vector machine model	Zhang, Jianhua Han, Jian Wang, Rui Hou, Guolian	(Zhang, Han, Wang, & Hou, 2011)
2013	Mid-term Electricity Market Clearing Price Forecasting Using Multiple Support Vector Machine	Yan, Xing Chowdhury, Nurul A	(Yan & Chowdhury, 2013)
2014	Forecasting energy markets using support vector machines	Papadimitriou, Theophilos Gogas, Periklis Stathakis, Efthimios	(Papadimitriou, Gogas, & Stathakis, 2014)
2014	Prediction interval Estimation for Electricity Price and Demand using Support Vector Machines	Shrivastava, Nitin Anand Khosravi, Abbas Panigrahi, Bijaya Ketan Memeber, Senior	(Shrivastava, Khosravi, Panigrahi, & Memeber, 2014)
2015	Prediction Interval Estimation of Electricity Prices using PSO tuned Support Vector Machines	Shrivastava, Nitin Anand Khosravi, Abbas Panigrahi, Bijaya Ketan	(Shrivastava, Khosravi, & Panigrahi, 2015)
2015	Electricity Price Forecasting Using Support Vector Machines by Considering Oil and Natural Gas Price Impacts	Ali Shiriz, Mohammad Afsharx, Ashkan Rahimi-Kianz y Behrouz Mahamz	(Ali Shiriz, Mohammad Afsharx & zSNL/CIPCE, School of Electrical and Computer Engineering, 2015)
2016	Support Vector Machines for decision support in electricity markets' strategic bidding	Pinto, Tiago Sousa, Tiago M. Praca, Isabel Vale, Zita Morais, Hugo	(Pinto, Sousa, Pra??a, Vale, & Morais, 2016)

**Fuente:** elaboración propia

Uno de los factores más importantes es precisamente la calidad de energía, ya que las consecuencias de una mala calidad pueden ser: sobretensiones, inmersión (caída), distorsiones armónicas, interrupciones, el parpadeo, etc. Esto representa perturbaciones en el buen funcionamiento de los equipos del cliente o usuario final (Siahkali, 2008).

Dos de las técnicas más comunes en el procesamiento de las señales eléctricas, son la transformada de Fourier y de wavelet, utilizadas para filtrar ruidos. Zhu (2005), en su investigación plantea la unión de la transformada de wavelet y la SVM, en un solo sistema de detección y clasificación de perturbaciones en una red de energía eléctrica, los resultados son plasmados en la tabla 3.

**Tabla 2.** Trabajos o investigaciones en la predicción de la demanda y consumo de electricidad usando SVM

Fecha de publicación	Título del artículo o investigación	Nombre de los autores	Referencia bibliográfica
2006	Support Vector Machines with PSO Algorithm for Short-Term Load Forecasting	Sun, Changyin Gong, Dengcai	(Sun & Gong, 2006)
2007	Applying support vector machine method to forecast electricity consumption	Yang, Shu Xia Wang, Yi	(Yang & Wang, 2007)
2008	with Least Squares Support Vector Machines	Wang, Yi Yu, Songqing	(Wang & Yu, 2008)
2011	Modeling and prediction of Turkey's electricity consumption using Support Vector Regression	Kavaklioglu, Kadir	(Kavaklioglu, 2011)
2011	Electrical load forecasting using support vector machines	Turkay, B E Demren, D	(Turkay & Demren, 2011)
2013	Demand elasticity analysis by least squares support vector machine	Xie, Li Zheng, Hua	(Xie & Zheng, 2013)

**Tabla 3.** Resultados de la clasificación basada en *wavelets* y FSVM

Tipo de perturbaciones PQ	Numero de perturbaciones	Número de casos en que se identificó correctamente	Número de casos en que falló la identificación	Identificación correcta (%)
Caída	1000	984	16	
Elevación	1000	990	10	
Interrupción	1000	980	20	
Armónico	1000	996	4	
Transitorio	1000	991	9	
Impulso	1000	974	26	
Parpadeo	1000	967	33	
Muesca	1000	960	40	
Suma	8000	7842	158	98

Fuente: Zhu (2005)

En esta investigación inicialmente utilizaron las ondas *spline* trigonométricas para eliminar el ruido de las señales, con el propósito de poder clasificar las perturbaciones más comunes expuestas en la tabla anterior.

Zhang, Chen, Liu y Zhao (2008) plantean una estrategia global para el correcto análisis de la red, para lo cual se generó la tabla 4 en la que se establecen los índices, los valores entre los que pueden variar y su clasificación dependiendo el caso.



**Tabla 4.** PQ índices y clasificación uniforme

Desviación de la tensión (%)	La fluctuación de voltaje (%)	Severidad del parpadeo a corto plazo (%)	Severidad del parpadeo largo plazo (%)	Total de distorsión armónica THD (%)	Desequilibrio de tensión trifásica (%)	La desviación de frecuencia (Hz)	Resultados de la clasificación	Nivel de PQ
$\leq 2$	$\leq 0.6$	$< 0.16$	$\leq 0.12$	$< 0.4$	$\leq 0.4$	$< 0.04$	1	excelente
(2,4]	(0.6,1.2]	(0.16,0.32]	(0.12,0.24]	(0.4,0.8]	(0.4,0.8]	(0.04,0.08]	0,9	mejor
(4,6]	(1.2,1.8]	(0.32,0.48]	(0.24,0.36]	(0.8,1.2]	(0.8,1.2]	(0.08,0.12]	0,8	bueno
(6,8]	(1.8,2.4]	(0.48,0.64]	(0.36,0.48]	(1.2,1.6]	(1.2,1.6]	(0.12,0.16]	0,7	inferior a la buena
(8,10]	(2.4,3]	(0.64,0.8]	(0.48,0.6]	(1.6,2]	(1.6,2]	(0.16,0.2]	0,6	media
(10,14]	(3,4.2]	(0.8,1.12]	(0.6,0.84]	(2,2.8]	(2,2.8]	(0.2,0.28]	0,5	moderadamente mala
(14,18]	(4.2,5.4]	(1.12,1.44]	(0.84,1.08]	(2.8,3.6]	(2.8,3.6]	(0.28,0.36]	0,4	malo
(18,22]	(5.4,6.6]	(1.44,1.76]	(1.08,1.32]	(3.6,4.4]	(3.6,4.4]	(0.36,0.44]	0,3	peor
$\geq 22$	$\geq 6.6$	$\geq 1.76$	$\geq 1.32$	$\geq 4.4$	$\geq 4.4$	$\geq 0.44$	0,2	peor

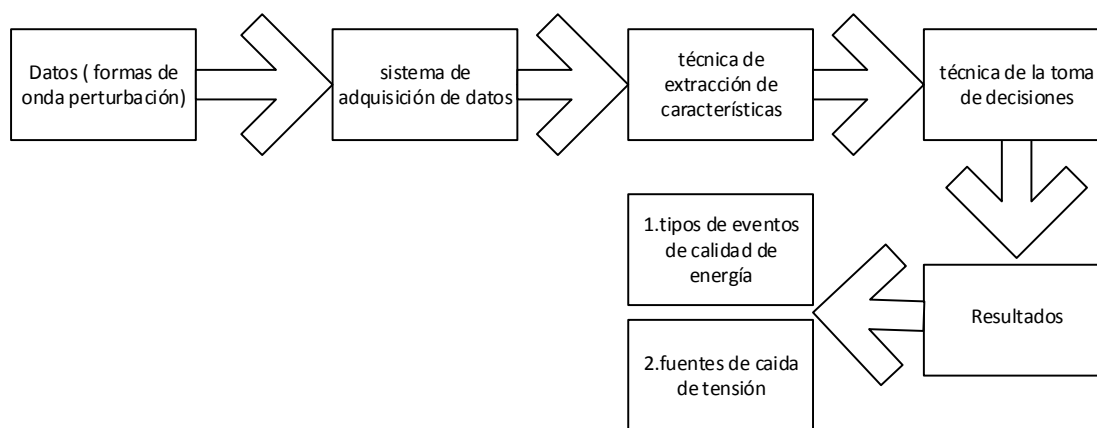
**Fuente:** Zhang *et al.* (2008)

El propósito de su trabajo es mostrar una estrategia de evaluación de calidad de potencia de sistemas eléctricos, basada en el método de lastre integrado y la SVM.

Un año más tarde, Susukh, Premrudeepreechacharn y Kasirawat (2009) desarrollan una investigación con el fin de utilizar las SVM para clasificar los tipos de perturbaciones eléctricas. Para ello hacen pruebas con las SVM, y los datos de una red de 22 KV de Tailandia Chiang Mai; utilizan un total de 450 señales de los diferentes tipos de perturbaciones, las cuales son pasadas a través de

la SVM ejecutada por medio de *MATLAB*, Lo que arroja como resultado que la SVM es capaz de clasificar las perturbaciones eléctricas las cuales en su trabajo sustentan son de cuatro tipos: interrupciones momentáneas, caídas de tensión, sobretensiones y muescas de tensión; con un 90 % de efectividad.

En Malasia se utilizaron las SVM con el fin de identificar las causas de las caídas de tensión en las redes de distribución (Faisal y Mohamed, 2009); la red está conectada a un sistema de monitoreo continuo, con el fin de supervisarla continuamente.

**Figura 3.** Flujo de proceso para la nueva técnica

**Fuente:** Faisal y Mohamed (2009).

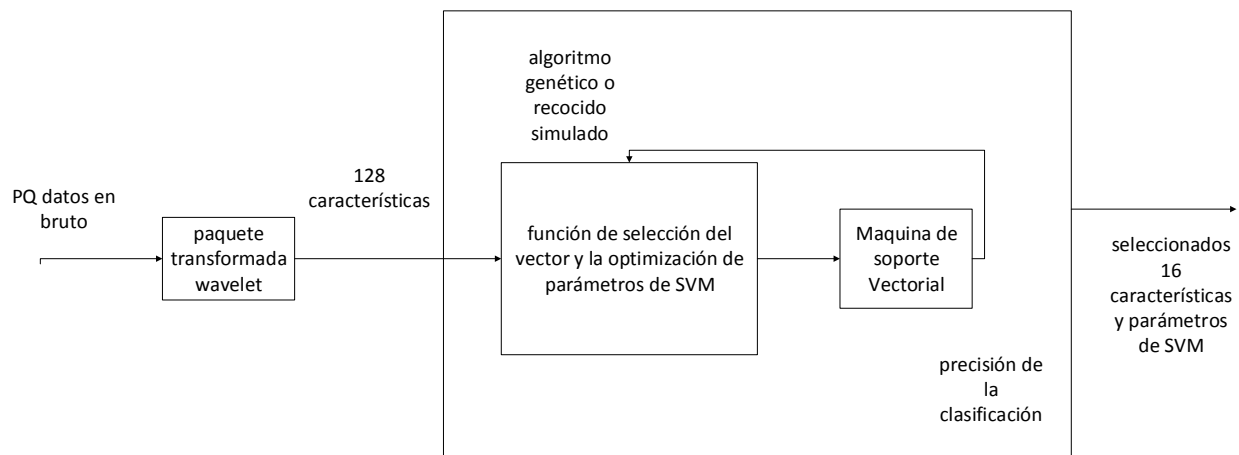
El sistema lleva el nombre de PQMS, y es acoplado a la SVM (figura 3).

Después de probar la SVM como medio para identificar las causas de las caídas de tensión, concluyen que el método es 100 % efectivo.

La transformada de *wavelet*, Manimala, Selvi y Ahila (2012), en su investigación, la combinan junto con una SVM, con el fin de mejorar la calidad de energía de un sistema (Manimala, Selvi y Ahila, 2012), el marco de su modelo está representado en la figura 4.


Al implementarlo y crear las fallas desde el sistema SimuLink de *MATLAB*, Manimala, Selvi y Ahila (2012) concluyen que la utilización la SVM mejora la precisión en la clasificación.

En 2013 Biswal, Biswal, Dash y Mishra publican una investigación, la cual tiene el objetivo de utilizar una SVM de cuatro etapas (figura 5), combinada con la *TT-transform* para detectar, localizar y clasificar perturbaciones en redes de energía eléctrica.



**Figura 4.** Marco del modelo propuesto

**Fuente:** (Manimala, Selvi y Ahila (2012)).



**Figura 5.** La red de soporte vectorial de cuatro capas (SVM)

**Fuente:** Biswal, Biswal, Dash y Mishra (2013).

## PÉRDIDAS NO TÉCNICAS DE ENERGÍA ELÉCTRICA

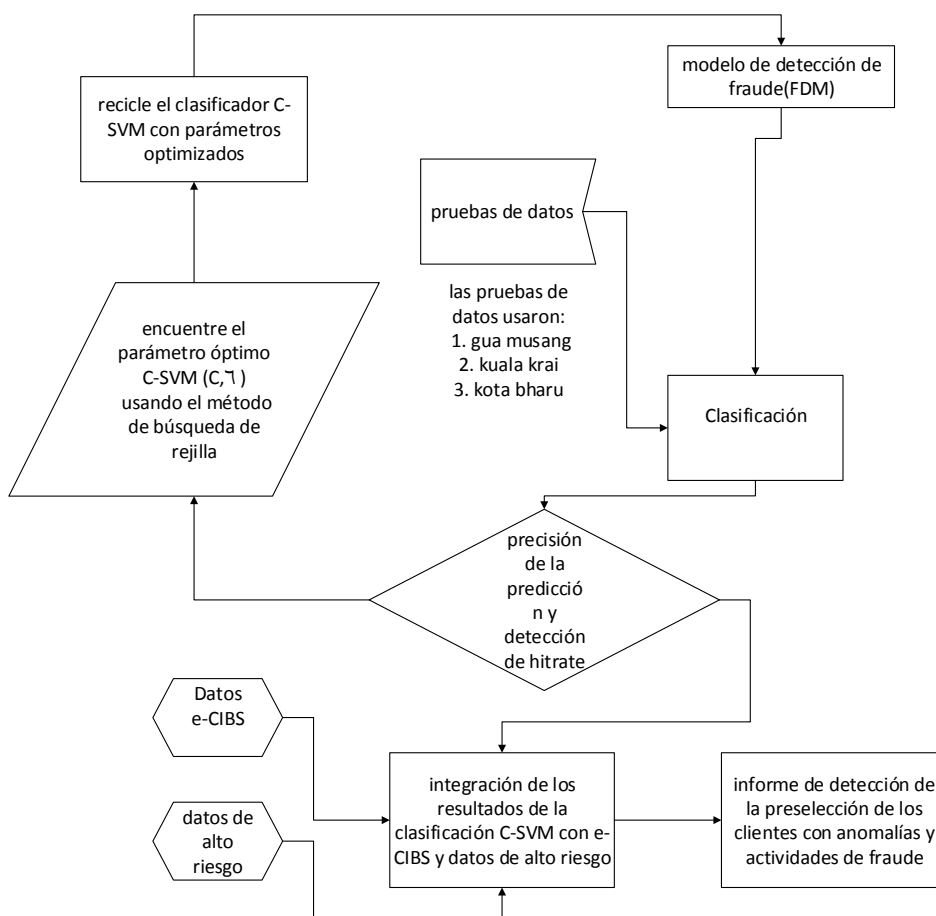
Nagi *et al.* (2010) plantean la utilización de SVM con el fin de minimizar las pérdidas no técnicas en Malasia, específicamente la empresa afectada es Tenaga Nasional Berhad (TNB) Sdn, puesto que las pérdidas por robo de energía y otros factores en 2004 ascendieron hasta US\$ 229 millones al año. Luego de clasificar los datos, dieron prioridad a aquellos que estaban más completos, y con mayor variación de consumo o con cambios fuertes en este.

La metodología que utilizaron para la detección de posibles clientes con fraude, se puede observar en la figura 6.

Un año más tarde, Shekara, Reddy, Wang y Devabhaktuni (2011) muestran que las pérdidas de energía en sus procesos de generación, transmisión y distribución son muy altos; el problema que plantean es que en generación se puede calcular de cuánto es la pérdida, pero en transmisión y distribución es más complejo.

Clasifican los clientes según su consumo mensual y su uso (residencial, comercial y agrícola), desarrollan su algoritmo de predicción con la SVM y concluyen que en una próxima investigación complementarán su modelo con un controlador inteligente.

Luego en 2015 en India utilizan una SVM acompañada de otros métodos de predicción y detección, para identificar posibles clientes fraudulentos,



**Figura 6.** Diagrama de flujo del motor de validación FDM para la detección de presuntos clientes (clientes con anomalías y actividades de fraude)

**Fuente:** Nagi *et al.* (2010).

la SVM es un apoyo al algoritmo general (Dangar y Joshi, 2015). Un año más tarde, Jokar, Arianpoo y Leung (2015) desarrollan un algoritmo donde se incluyen las SVM, cumpliendo estas una función de detectar anomalías en el perfil del cliente y es apoyo en el proceso general, que se basa en las pérdidas en el nivel de transformación.


## ENERGÍAS ALTERNATIVAS

Actualmente las energías alternativas o limpias están tomando una gran fuerza debido al fenómeno

del calentamiento global provocado por gases que son derivados de procesos industriales, entre ellos la generación de energía por combustibles fósiles o derivados. Se ha trabajado directa o indirectamente en ellas con las SVM como se verá a continuación.


## Eólica

Pinto, Ramos, Sousa y Vale (2014), en su trabajo muestran la utilización de las SVM, para predecir la velocidad del viento a corto plazo, la información para ello fue tomada de la base de datos del



**Figura 7.** Datos de radiación solar por hora en un gráfico de tiempo 1D.

**Fuente:** Zeng y Qiao (2013).



**Figura 8.** Una vista de la imagen 2D de los datos de radiación solar

**Fuente:** Zeng y Qiao (2013).

Laboratorio Nacional de Energía Renovable ([http://www.nre1.gov/midc/nwtc\\_m2](http://www.nre1.gov/midc/nwtc_m2)). Luego de desarrollar su algoritmo utilizando *MATLAB* para este fin, logran comprobar que el rendimiento de la SVM es mucho mejor que otros métodos anteriormente usados para el mismo propósito, como las redes neuronales.

De igual manera, Kong, Liu, Shi y Lee (2015) desarrollan un algoritmo para predecir la velocidad del viento con una SVM de regresión de datos (RSVM), apoyada en métodos de selección de datos denominados PCA y PSO.

## Solar o fotovoltaica


Es de vital importancia conocer el índice de radiación solar, para su aprovechamiento como energía, por esto Zeng y Qiao (2013) en su investigación plantean la implementación de SVM y la utilización de la base de datos de radiación solar (NSRDB) de Estados Unidos, la cual contiene datos desde 1991 a 2005 en diferentes regiones del país, los datos son tratados en una dimensión (figura 7) y en dos dimensiones (figura 8) con el fin de analizarlos mejor.

Luego de utilizar los datos descritos anteriormente Zeng y Qiao (2013) dan a conocer una serie de gráficos de las predicciones de la SVM en dos ciudades distintas: Denver y Seattle, una de ellas descrita en la figura 9.

Al comparar los resultados con la SVM con los de otros métodos utilizados para la misma tarea, Zeng y Qiao (2013) concluyen que la SVM tiene un rendimiento mucho mejor debido a su manejo especial de los datos.

Liu *et al.* (2012) realizan una investigación acerca de los colectores solares cilindro-parabólicos con el fin de utilizar una SVM para su modelamiento y optimización, tomando como datos para la investigación dos sistemas de 30 y 600 metros cuadrados de campo solar en China.

La SVM fue utilizada en la planta de 600 m<sup>2</sup>, en la que se emplearon datos de entrada como: flujo solar, temperatura de entrada y de salida. La eficiencia del colector fue la salida de la SVM. Liu *et al.* (2012) concluyen su trabajo diciendo que la SVM basándose en los resultados, es muy acertada en cuanto al modelo y a la optimización de los colectores cilindro-parabólicos, ya que son parte fundamental del sistema de generación solar.



**Figura 9.** La predicción de una hora en Denver utilizando SVM


**Fuente:** Zeng y Qiao (2013).

Se estima que la capacidad instalada de generación fotovoltaica global es de alrededor de 138,9 GW, y lo más factible es que siga aumentando; por ello Antonanzas *et al.* (2015) en su investigación, plantean la utilización de SVM con el fin de estimar la irradiación solar globalmente, tomando como lugar de estudio España. Luego de las pruebas en 14 estaciones meteorológicas del país, el resultado fue que la SVM es sumamente eficiente y más precisa, ya que el error más alto generado en el estudio fue de 7,38 % en comparación con los otros métodos y modelos.

En otros trabajos se plantea una metodología combinada, en la cual se incluye tanto la SVM como la transformada de *wavelet* (WT) para predecir la radiación solar. Este método ha sido denominado como SVM-WT en la investigación de Mohammadi *et al.* (2015), su modelo está basado en que los datos utilizados son fácilmente medibles y, en general, están disponibles en todo lugar,

evitando así marginar a las zonas más atrasadas tecnológicamente; algunos de ellos son: latitud, altitud, temperatura ambiente, nubosidad, etc. Los datos utilizados pertenecen al puerto de Bandar Abass, en Irán, el método de clasificación de datos para la SVM se aprecia en la figura 10.

En su investigación, Mohammadi *et al.* (2015) hacen varios estudios, uno de ellos es la estimación global de la radiación diaria, para la cual hacen una comparación con otros métodos y modelos utilizados para ello como: “la red neuronal artificial (ANN), la programación genética (GP) y autorregresivo media móvil (ARMA)”. Y los índices de comparación son cinco: error medio porcentual absoluto (MAPE), media de error de desviación absoluto (MABE), error medio cuadrático (RMSE), la raíz cuadrada del anterior (RRMSE) y por último el coeficiente de determinación ( $R^2$ ), arrojando como resultado lo consignado en la tabla 5.



**Figura 10.** Diagrama de flujo del método de determinación de parámetros basada en ondas propuesto para el clasificador SVM.

**Fuente:** Mohammadi *et al.* (2015).

**Tabla 5.** Parámetros estadísticos obtenidos para los modelos SVM-WT híbridos desarrollados, así como los modelos ANN, GP y ARMA para el análisis diario.

Modelo	MAPE	MABE	RMSE	RRMSE	R 2
SVM-WT (1)	155.954	21.150	26.475	147.692	0.6844
SVM-WT (2)	155.306	21.463	26.911	150.125	0.6880
SVM-WT (3)	69.996	0.8405	14.245	79.467	0.9086
ANN (1)	171.042	22.039	28.519	159.095	0.6339
ANN (2)	164.115	22.071	27.776	154.950	0.6527
ANN (3)	93.080	0.9395	18.415	102.729	0.8649
GP (1)	171.882	22.159	28.417	158.526	0.6364
GP (2)	163.904	22.073	27.811	155.145	0.6518
GP (3)	93.233	0.9473	18.494	103.170	0.8622
ARMA (1)	173.239	22.172	28.549	159.262	0.6341
ARMA (2)	161.091	22.294	27.975	156.060	0.6527
ARMA (3)	94.033	0.9668	18.804	104.899	0.8573

Fuente: Mohammadi *et al.* (2015).

De esta manera se comprueba que el modelo SVM-WT tiene un buen desempeño en comparación de los otros métodos y representa una herramienta útil y precisa para dicho estudio. Un año más tarde, Shamshirband *et al.* (2016) realizan una investigación con este mismo método en la ciudad de Kerman en el mismo país, para estimar la radiación solar difusa, obteniendo resultados similares en cuanto a la efectividad y utilidad del método.

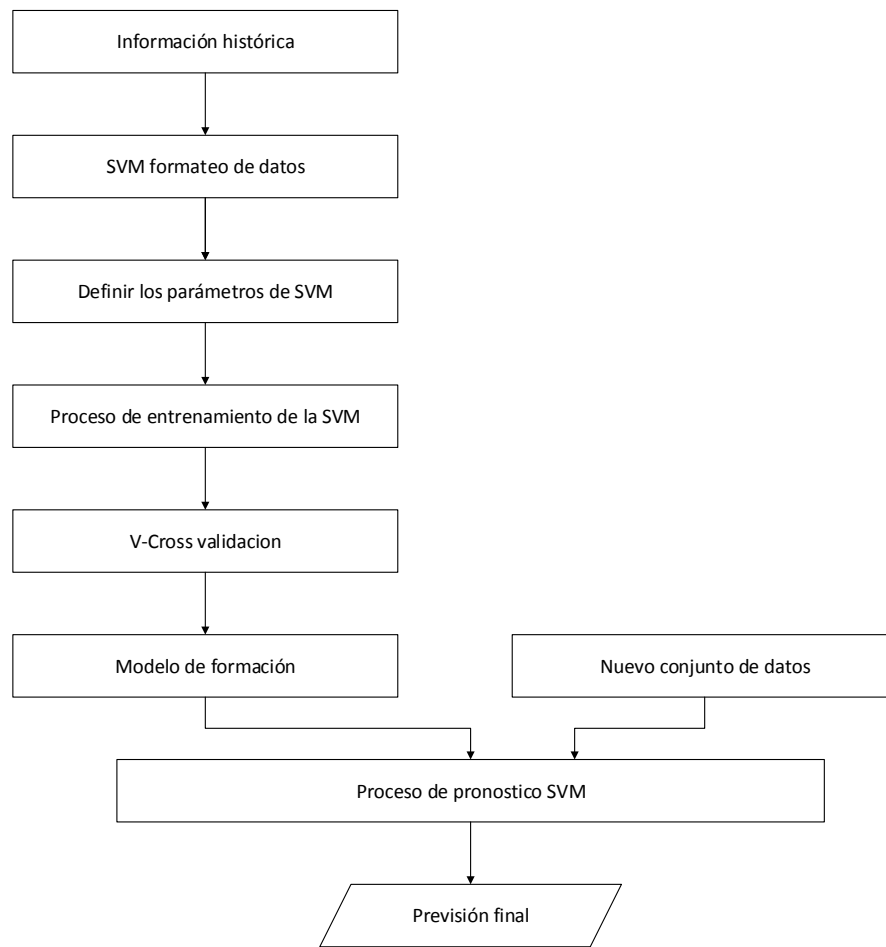
## PIEZOELÉCTRICOS

Ma, Zhang, Xu y Xie (2013) presentan un modelo combinando la SVM con el modelo de Preisach para representar la histéresis y los diferentes efectos dinámicos del piezoeléctrico, algo que con el modelo de Preisach era complicado, pues este necesitaba gran cantidad de datos que no eran de fácil adquisición. El actuador piezoeléctrico utilizado en esta investigación es un PTBS200 (de forma apilada), el cual tiene como límites de saturación -30V y +150V, la prueba es realizada inyectándole

una señal cuadrada con los límites ya mencionados y comparándola con resultados experimentales y calculados con el método de Preisach, lo cual arrojó como resultado el buen desempeño del modelo desarrollado en la investigación “La comparación entre la salida del modelo híbrido y los datos experimentales produjo un error medio FSR de 1,03% y un error máximo de 2,37%”.

## VEHÍCULOS ELÉCTRICOS

La introducción de vehículos eléctricos en el mercado plantea una alternativa para la contaminación global actual, como también un reto para pronosticar la demanda de energía que se necesitará para satisfacer esta nueva tecnología, con el fin de minimizar problemas en la red de energía eléctrica. Por ello, Xydas *et al.* (2013) plantean un modelo basado en SVM con el fin de pronosticar esta demanda a corto plazo en el Reino Unido; el diagrama de flujo que describe este modelo se puede observar en la figura 11.

**Figura 11.** Flujo de operación del modelo SVM

**Fuente:** Xydias *et al.* (2013).

Luego de realizar las pruebas con la SVM, Xydias *et al.* (2013) comparan los resultados con el método Monte Carlo, los cuales son muy positivos para la SVM ya que tiene una mayor sensibilidad a los cambios y, por tanto, su error es menor.

Un elemento esencial en esta tecnología con la baterías almacenadoras de energía, por lo cual se hace necesario el predecir su funcionamiento y prevenir posibles fallos en las mismas. Klass, Behm y Lindbergh (2014) plantean la utilización de SVM en baterías de ion de litio; las características de estas son descritas en la tabla 6. Las pruebas son denominadas SOH (pruebas de rendimiento estándar), luego de realizar las pruebas y simulaciones virtuales se encuentra que la SVM es de gran

utilidad ya que sus salidas son bastante acertadas y no se necesita de equipo adicional para realizar el estudio.

**Tabla 6.** Especificaciones de las células de las baterías de iones de litio probadas

Capacidad nominal Q nom	17,5 Ah
Tensión máxima T max	4.1 V
Tensión mínima de U min	2,5 V
Corriente continua máxima I máx	35 A
electrodo positivo	óxido mixto
electrodo negativo	de carbono duro
Dimensiones	253 × 172 × 5,8 mm

**Fuente:** Klass, Behm y Lindbergh (2014).



## TRANSFORMADORES

El transformador es uno de los elementos más importantes y costoso en el proceso de distribución eléctrica; su buen funcionamiento es esencial para garantizar la prestación del servicio eléctrico a los usuarios conectados a él. Por lo general, el esfuerzo eléctrico y térmico al que está expuesto un transformador es la principal causa de daño o fallo en este; en algunos casos se deteriora el aislante, generando así la liberación de gases tóxicos a la atmósfera. Uno de los métodos para la predicción de fallos más utilizado se denomina método de análisis de gas disuelto (DGA). En su investigación, Zhu, Zhao, Zhai y Zhang (2007) plantean la utilización de SVM para analizar los datos del DGA, con el fin

de predecir comportamientos futuros del transformador; se toma como prueba uno de 110 kV en la provincia de Jiangsu de 1990 a 1995, asumiendo así los datos hasta 1993 como entrenamiento de la SVM y los de 1994-1995 de prueba de esta.

En las tablas 7 y 8 se pueden apreciar los datos utilizados y los resultados con los mismos respectivamente, obteniendo como conclusión que la SVM es útil en la predicción de comportamientos futuros de transformadores y sus resultados son mucho más eficientes que los obtenidos con otros métodos tradicionales. Más adelante, Mehta (2013) utiliza los datos DGA para pronosticar los fallos en los transformadores utilizando un algoritmo distinto pero obteniendo resultados semejantes en cuanto a su eficacia se refiere.

**Tabla 7.** La DGA datos del transformador de energía

Año	$H_2$	$CH_4$	$C_2H_6$	$C_2H_4$	$C_2H_2$	$CO$	$CO_2$
1990	18.37	24.20	3.40	2.71	0	120.1	500
1991	19.42	24.70	3.80	2.89	0	154.3	678
1992	27.30	25.40	3.70	2.52	0	178.0	681
1993	22.40	22.30	3.50	2.64	0	220	750
1994	23.70	23.50	3.70	2.95	0	256	738
1995	24.80	23.80	3.64	2.70	0	2.86	788

**Fuente:** Zhu, Zhao, Zhai y Zhang (2007).

**Tabla 8.** Resultados experimentales utilizando el modelo SVM

Ítem	1995 Actual	1995 Prueba	Error $\delta$ (%)
$H_2$	24.80	24.21	2.38
$CH_4$	23.80	23.20	2.52
$C_2H_6$	3.64	3.62	0.55
$C_2H_4$	2.70	2.76	-2.22
$C_2H_2$	0	0	0
$CO$	286	284	0.70
$CO_2$	788	778	1.27

**Fuente:** Zhu, Zhao, Zhai y Zhang (2007).

Loizos (2009) utiliza la SVM con el fin de predecir las pérdidas en los transformadores (por lo general en el núcleo y en el cobre) puesto que una reducción

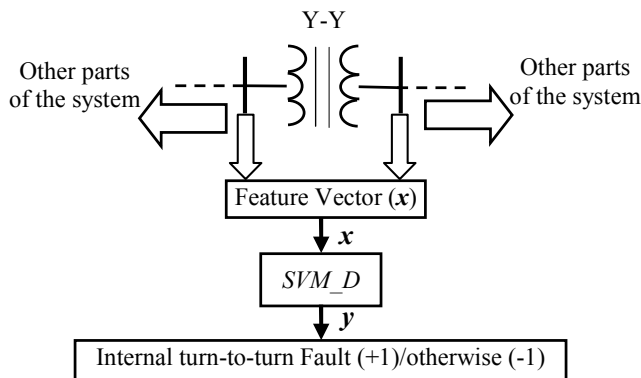
en ellas puede generar un gran beneficio económico para la empresa. En la tabla 9 se aprecian las variables de entrada y de salida del algoritmo.

**Tabla 9.** Las variables de entrada

Las variables de entrada	
Variable	Unidad
peso del núcleo	kg
Voltaje aplicado	kV
Las corrientes de fase (A, B, C)	UN
Fase de corriente media	UN
HiB o CGO	Sin unidades-1 o 0
Variables de salida	
Las pérdidas de potencia del núcleo	kW

**Fuente:** Loizos (2009).

Por otro lado, Elsamahy y Babiy (2012) utilizan SVM con el fin de ayudar a detectar fallas en el aislamiento interno del transformador en situaciones tan reducidas, como el daño entre una vuelta y otra del embobinado; estos fallos son detectables solo cuando hay comprometido (en cortocircuito) un 10 % del devanado. El esquema utilizado para la detección de fallos con la SVM se presenta en la figura 12, luego de realizar las pruebas encuentran que la SVM es capaz de predecir los fallos de una vuelta a otra, además de discriminar los fallos externos, teniendo un rendimiento del 96,2 %.



**Figura 12.** Diagrama de bloques del esquema basado en SVM

**Fuente:** Elsamahy y Babiy (2012).

La predicción es un papel importante, al igual que el conocer el estado de salud del aislamiento en el transformador. Por ello, Ashkezari, Ma, Saha y Ekanayake (2013) desarrollan una investigación con el fin de utilizar una SVM en este proceso, acoplándola con datos obtenidos de varias pruebas hechas a los transformadores, para así mejorar el diagnóstico de la salud del aislamiento (papel/aceite). Las pruebas se realizan con los datos de un estudio DGA en 181 transformadores en servicio, lo que arroja como resultado que el acoplamiento de la SVM en este proceso es de gran utilidad para mejorar el nivel del pronóstico de la salud en los transformadores en servicio.

## OTRAS APLICACIONES


### Reles

La principal función de un relé inteligente es el de desconectar un equipo cuando las condiciones eléctricas para este no sean las apropiadas, pero en algunos casos muy especiales no se reconoce si se encuentra en medio de un fallo o de una condición normal del sistema. Para mejorar su precisión en la detección de fallos, Zhang, Ilic y Tonguz (2007) plantean la utilización de SVM, uno de los resultados es que esta es capaz de detectar la falla cuando esta se encuentra en medio de la red de transmisión, algo que el relé no era capaz de diferenciar. Realizaron simulaciones en *MATLAB* para la clasificación los datos; los *software* para las pruebas fueron *Matpower* y *LIBSVM*. Los autores concluyen que la utilización de SVM es viable para esta aplicación con base en los resultados obtenidos.

### Aisladores

Bessedik y Hadi (2013) sugieren el uso de SVM combinada con otros modelos (mínimos cuadrados y optimización de enjambre de partículas) para predecir la tensión de descarga de dichos modelos, en diferentes condiciones ambientales. Las pruebas para ello se realizaron en el Laboratorio de Alta Tensión de la Compañía Nacional de Electricidad.

Los resultados de las pruebas se pueden observar en la figura 13. Por otro lado, comparan los resultados entre los dos métodos planteados en este trabajo (LS-SVM-PSO y LS-SVM-GS) con otros métodos utilizados regularmente para lo mismo; plantean tres casos, los cuales se diferencian en la manera de adquirir los datos y procesarlos, y encuentran que su método es más preciso en la predicción del flameo de los aisladores.



**Figura 13.** La comparación entre los datos experimentales y los valores estimados para el conjunto de prueba

**Fuente:** Bessedik y Hadi (2013).


## Interruptores de alta tensión

En busca de predecir la vida mecánica de los aisladores en alta tensión y así evitar interrupciones en el sistema de energía eléctrica, Zhang, Huang y Yao (2015) plantean la utilización de SVM, para lo

cual tienen en cuenta dos variables principales: la curva de desplazamiento mecánico del aislador y la curva de la corriente de apertura de la bobina; en conclusión, la SVM es de gran utilidad puesto que los aisladores durante su vida útil solo trabajan unas pocas veces, lo cual reduce los datos relacionados a las fallas por las que trabajaron y la SVM generaliza muy bien los pocos datos que le son suministrados.

## Fallas en cables subterráneos

Ngaopitakkul, Pothisarn, Bunjongjit y Suechoey (2012) desarrollan un método basado en SVM y la transformada de wavelet (utilizada para descomponer las señales de las fallas a alta frecuencia) con el fin de clasificar los fallos en los cables de distribución subterránea. Para ello simulan señales de fallo a una velocidad de 200 kHz, suponen la resistencia de fallo como  $10\Omega$ . En la figura 14 se puede observar la estructura de la SVM para clasificar los tipos de fallo en este tipo de cables, obteniendo resultados muy buenos en cuanto a la detección de la falla.



**Figura 14.** Estructura de SVM para clasificar tipos de fallo

**Fuente:** Ngaopitakkul, Pothisarn, Bunjongjit y Suechoey (2012).

## CONCLUSIONES:

En este artículo se presentó una revisión de trabajos realizados con base en las SVM's, con el fin de generar un apoyo para futuros trabajos en el mismo campo.

Las SVM's son una herramienta que tomo una gran fuerza y participación en todos los campos de la ciencia, debido a: los buenos resultados obtenidos en estudios realizados; son de una gran versatilidad en sus aplicaciones y en la mayoría de los casos presentan una exactitud mayor en los resultados en contraste con otros métodos.

Una de las características más relevantes de las SVM's es que pueden ser utilizadas en cualquier ámbito sin necesidad de que tengan conocimientos previos del mismo, siempre y cuando se tengan datos con los cuales entrenarla.

Los algoritmos SVM's han sido y están siendo altamente utilizados en sistemas eléctricos más específicamente en la predicción de demanda, predicción de consumo, y en la predicción de hurto de energía; actualmente están siendo utilizadas en otros campos como las energías alternativas, planteando una posibilidad para futuros estudios en esta y otras ramas poco exploradas con las SVM's.

La SVM puede utilizarse para contemplar casos en los que: Existe ruido en las muestras de entrenamiento; Los datos tienen cierto grado de solapamiento entre clases, puede ser extendido al caso no lineal. Al ser una herramienta que no ha sido utilizada en varios temas a nivel eléctrico, se genera un nicho de investigación futura.

## REFERENCIAS

- Ali Shiriz, Mohammad Afsharx, A. R.-K. and B. M., & zSNL/CIPCE, School of Electrical and Computer Engineering, C. of E. (2015). Electricity Price Forecasting Using Support Vector Machines by Considering Oil and Natural Gas Price Impacts, 2–6.
- Antonanzas, F.; Urraca, R.; Antonanzas, J.; Fernandez, J. y Martinez-de-Pison, F.J. (2015). Generation of Daily Global Solar Irradiation with Support Vector Machines for Regression. *Energy Conversion and Management*, 96, 277–286. <http://doi.org/10.1016/j.enconman.2015.02.086>
- Ashkezari, A.D.; Ma, H.; Saha, T.K. y Ekanayake, C. (2013). Application of Fuzzy Support Vector Machine for Determining the Health Index of the Insulation System of In-Service Power Transformers. *Dielectrics and Electrical Insulation, IEEE Transactions on*, 20(3), 965–973. <http://doi.org/10.1109/TDEI.2013.6518966>
- Bessedik, S.A. y Hadi, H. (2013). Prediction of Flash-over Voltage of Insulators Using Least Squares Support Vector Machine with Particle Swarm Optimisation. *Electric Power Systems Research*, 104, 87–92. <http://doi.org/10.1016/j.epsr.2013.06.013>
- Betancour, G. (2005). Las máquinas de soporte vectorial (SVM). *Scientia Et Technica*, 27, 67–72.
- Biswal, B.; Biswal, M.K.; Dash, P.K. y Mishra, S. (2013). Power Quality Event Characterization Using Support Vector Machine and Optimization Using Advanced Immune Algorithm. *Neurocomputing*, 103, 75–86. <http://doi.org/10.1016/j.neucom.2012.08.031>
- Che, J. y Wang, J. (2010). Short-Term Electricity Prices Forecasting Based on Support Vector Regression and Auto-Regressive Integrated Moving Average Modeling. *Energy Conversion and Management*, 51(10), 1911–1917. <http://doi.org/10.1016/j.enconman.2010.02.023>
- Dangar, B. y Joshi, S.K. (2015). Electricity Theft Detection Techniques for Metered Power Consumer in Guvnl, Gujarat, India. *2015 Clemson University Power Systems Conference (PSC)* (pp. 1–6). Clemson. <http://doi.org/10.1109/PSC.2015.7101683>
- Elsamahy, M. y Babiy, M. (2012). An Intelligent Approach Using SVM to Enhance Turn-To-Turn Fault Detection in Power Transformers. *2012 IEEE Electrical Power and Energy Conference* (pp. 255-260). Londres. <http://doi.org/10.1109/EPEC.2012.6474961>
- Faisal, M.F. y Mohamed, A. (2009). Identification of Sources of Voltage Sags in the Malaysian Distribution Networks Using SVM Based S-Transform. *TENCON 2009–2009 IEEE Region 10 Conference*

- (pp. 1–6). Singapur. <http://doi.org/10.1109/TENCON.2009.5395940>
- Gao, C.; Bompard, E.; Napoli, R. y Cheng, H. (2007). Price Forecast in the Competitive Electricity Market by Support Vector Machine. *Physica A: Statistical Mechanics and Its Applications*, 382(1), 98–113. <http://doi.org/10.1016/j.physa.2007.03.050>
- Goddard, J.; Silva, G.; Pérez, R. y Ángel M. (2000). Un algoritmo para el entrenamiento de máquinas de vector soporte para regresión. *Revista de Matemática: Teoría y Aplicaciones* 2000, 7(1-2), 107–116.
- Jokar, P.; Arianpoo, N. y Leung, V.C.M. (2015). Electricity Theft Detection in AMI Using Customers' Consumption Patterns. *IEEE Transactions on Smart Grid*, 7(1), 216–226. <http://doi.org/10.1109/TSG.2015.2425222>
- Kavaklioglu, K. (2011). Modeling and Prediction of Turkey's Electricity Consumption Using Support Vector Regression. *Applied Energy*, 88(1), 368–375. <http://doi.org/10.1016/j.apenergy.2010.07.021>
- Klass, V.; Behm, M. y Lindbergh, G. (2014). A Support Vector Machine-Based State-Of-Health Estimation Method for Lithium-Ion Batteries Under Electric Vehicle Operation. *Journal of Power Sources*, 270, 262–272. <http://doi.org/10.1016/j.jpowsour.2014.07.116>
- Kong, X.; Liu, X.; Shi, R. y Lee, K.Y. (2015). Wind Speed Prediction Using Reduced Support Vector Machines with Feature Selection. *Neurocomputing*, 169, 449–456. <http://doi.org/10.1016/j.neucom.2014.09.090>
- Liu, Q.; Yang, M.; Lei, J.; Jin, H.; Gao, Z. y Wang, Y. (2012). Modeling and Optimizing Parabolic Trough Solar Collector Systems Using the Least Squares Support Vector Machine Method. *Solar Energy*, 86(7), 1973–1980. <http://doi.org/10.1016/j.solener.2012.01.026>
- Loizos, G. y Passadis, K. (2009). Core Power Losses Estimation of Wound Core Distribution Transformers with Support Vector Machines. *16th International Conference on Systems, Signals and Image Processing* (pp. 1-4). Chalkida.
- Luo, T.; Hall, L.O.; Goldgof, D.B. y Remsen, A. (2005). Bit Reduction Support Vector Machine. *Proceedings—IEEE International Conference on Data Mining, ICDM*, 733–736. <http://doi.org/10.1109/ICDM.2005.36>
- Ma, Y.; Zhang, X.; Xu, M. y Xie, S. (2013). Hybrid Model Based on Preisach and Support Vector Machine for Novel Dual-Stack Piezoelectric Actuator. *Mechanical Systems and Signal Processing*, 34(1-2), 156–172. <http://doi.org/10.1016/j.ymssp.2012.05.015>
- Manimala, K.; Selvi, K. y Ahila, R. (2012). Optimization Techniques for Improving Power Quality Data Mining Using Wavelet Packet Based Support Vector Machine. *Neurocomputing*, 77(1), 36–47. <http://doi.org/10.1016/j.neucom.2011.08.010>
- Mehta, A.K.; Sharma, R.N.; Chauhan, S. y Saho, S. (2013). Transformer Diagnostics under Dissolved Gas Analysis Using Support Vector Machine. *Power, Energy and Control (ICPEC), 2013 International Conference* (pp. 181–186). Dindigul.
- Mohammadi, K.; Shamshirband, S.; Tong, C.W.; Arif, M.; Petković, D. y Sudheer, C. (2015). A New Hybrid Support Vector Machine-Wavelet Transform Approach for Estimation of Horizontal Global Solar Radiation. *Energy Conversion and Management*, 92, 162–171. <http://doi.org/10.1016/j.enconman.2014.12.050>
- Nagi, J.; Yap, K.S.; Tiong, S.K.; Ahmed, S.K. y Mohamad, M. (2010). Nontechnical Loss Detection for Metered Customers in Power Utility Using Support Vector Machines. *IEEE Transactions on Power Delivery*, 25(2), 1162–1171. <http://doi.org/10.1109/TPWRD.2009.2030890>
- Ngaopitakkul, A.; Pothisarn, C.; Bunjongjit, S. y Suechoey, B. (2012). An Application of Discrete Wavelet Transform and Support Vector Machines Algorithm for Classification of Fault Types on Underground Cable. *Proceedings—3rd International Conference on Innovations in Bio-Inspired Computing and Applications, IBICA 2012* (pp. 85–88). Kaohsiung. <http://doi.org/10.1109/IBICA.2012.21>
- Osman, Z.H.; Awad, M.L. y Mahmoud, T. K. (2009). Neural Network Based Approach for Short-Term Load Forecasting. *2009 IEEE/PES Power Systems Conference and Exposition* (pp. 1–8). Seattle. <http://doi.org/10.1109/PSCE.2009.4840035>

- Papadimitriou, T.; Gogas, P. y Stathakis, E. (2014). Forecasting Energy Markets Using Support Vector Machines. *Energy Economics* (pp. 135–142). <http://doi.org/10.1016/j.eneco.2014.03.017>
- Pinto, T.; Ramos, S.; Sousa, T.M. y Vale, Z. (2014). Short-Term Wind Speed Forecasting Using Support Vector Machines. *Computational Intelligence in Dynamic and Uncertain Environments (CIDUE), 2014 IEEE Symposium* (pp. 40–46). Orlando
- Pinto, T.; Sousa, T.M.; Praa, I.; Vale, Z. y Morais, H. (2016). Support Vector Machines for Decision Support in Electricity Markets' Strategic Bidding. *Neurocomputing*, 172, 438–445. <http://doi.org/10.1016/j.neucom.2015.03.102>
- Qu, H.; Oussar, Y.; Dreyfus, G. y Xu, W. (2009). Regularized Recurrent Least Squares Support Vector Machines. 2009 International Joint Conference on Bioinformatics, Systems Biology and Intelligent Computing (pp. 508–511). Shanghai. <http://doi.org/10.1109/IJCBS.2009.58>
- Resendiz T., J.; Yu, W. y Li, X. (2006). Support Vector Machine for Nonlinear System On-line Identification. 2006 3rd International Conference on Electrical and Electronics Engineering pp. 1–4. Veracruz.
- Shamshirband, S.; Mohammadi, K.; Khorasanizadeh, H.; Yee, P.L.; Lee, M.; Petković, D. y Zalnezhad, E. (2016). Estimating the Diffuse Solar Radiation Using a Coupled Support Vector Machine-Wavelet Transform Model. *Renewable and Sustainable Energy Reviews*, 56, 428–435. <http://doi.org/10.1016/j.rser.2015.11.055>
- Shekara, S.; Reddy, S.; Wang, L. y Devabhaktuni, V. (2011). Support Vector Machine Based Data Classification for Detection of Electricity Theft. *IEEE/PES Power Systems Conference and Exposition (PSCE)* (pp. 1–8). Phoenix
- Shrivastava, N.A.; Khosravi, A. y Panigrahi, B.K. (2015). Prediction Interval Estimation of Electricity Prices using PSO tuned Support Vector Machines. *IEEE Transactions on Industrial Informatics*, 11(2), 1–1. <http://doi.org/10.1109/TII.2015.2389625>
- Shrivastava, N.A.; Khosravi, A.; Panigrahi, B.K. y Memeber, S. (2014). Prediction Interval Estimation for Electricity Price and Demand Using Support Vector Machines. *IEEE Transactions on Industrial Informatics*, 11(2), 322–331.
- Siahkali, H. (2008). Power Quality Indexes for Continue and Discrete Disturbances in a Distribution Area. *PECon 2008–2008 IEEE 2nd International Power and Energy Conference*, (PECon 08) (pp. 678–683). Johor Bahru. <http://doi.org/10.1109/PECON.2008.4762561>
- Sun, C., & Gong, D. (2006). Support Vector Machines with PSO Algorithm for Short-Term Load Forecasting. 2006 IEEE International Conference on Networking, Sensing and Control, 676–680. <http://doi.org/10.1109/ICNSC.2006.1673227>
- Susukh, J., Premrudeepreechacharn, S., & Kasi-rawat, T. (2009). Power quality problem classification using support vector machine. 2009 6th International Conference on Electrical Engineering Electronics Computer Telecommunications and Information Technology, 01, 2–5. <http://doi.org/10.1109/ECTICON.2009.5136965>
- Swief, R. a., Hegazy, Y. G., Abdel-Salam, T. S., & Bader, M. . (2009). Support vector machines (SVM) based short term electricity load-price forecasting. 2009 IEEE Bucharest PowerTech, 1–5. <http://doi.org/10.1109/PTC.2009.5281886>
- Turkay, B. E., & Demren, D. (2011). Electrical load forecasting using support vector machines. *Electrical and Electronics Engineering (ELECO), 2011 7th International Conference on*, 1–49–1–53.
- Wang, Y., & Yu, S. (2008). with Least Squares Support Vector Machines, (April), 714–719.
- Xie, L., & Zheng, H. (2013). Demand elasticity analysis by least squares support vector machine. *Proceedings of the 2013 6th International Congress on Image and Signal Processing, CISP 2013*, 2(Cisp), 1085–1089. <http://doi.org/10.1109/CISP.2013.6745217>
- Xydas, E. S., Marmaras, C. E., Cipcigan, L. M., Hassan, A. S., & Jenkins, N. (2013). Forecasting Electric Vehicle charging demand using Support Vector Machines. 2013 48th International Universities' Power Engineering Conference (UPEC), 1–6. <http://doi.org/10.1109/UPEC.2013.6714942>
- Yan, X., & Chowdhury, N. A. (2013). Mid-term Electricity Market Clearing Price Forecasting Using Multiple

- Support Vector Machine. *2013 4th IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe)*, 1–5.
- Yang, S. X., & Wang, Y. (2007). Applying support vector machine method to forecast electricity consumption. *2006 International Conference on Computational Intelligence and Security, ICCIAS 2006*, 1, 929–932. <http://doi.org/10.1109/ICCIAS.2006.294275>
- Yan-Gao, C. Y.-G. C., & Guangwen, M. G. M. (2009). Electricity Price Forecasting Based on Support Vector Machine Trained by Genetic Algorithm. *2009 Third International Symposium on Intelligent Information Technology Application*, 2, 293–296. <http://doi.org/10.1109/IITA.2009.96>
- Yucheng, L. y Yubin, L. (2010). Incremental Learning Method of Least Squares Support Vector Machine. *2010 International Conference on Intelligent Computation Technology and Automation*, 1, 529–532. Recuperado de: <http://doi.org/10.1109/ICICTA.2010.104>
- Zeng, J. y Qiao, W. (2013). Short-Term Solar Power Prediction Using a Support Vector Machine. *Renewable Energy*, 52, 118–127. <http://doi.org/10.1016/j.renene.2012.10.009>
- Zhang, J., Han, J., Wang, R., & Hou, G. (2011). Day-ahead electricity price forecasting based on rolling time series and least square-support vector machine model. *2011 Chinese Control and Decision Conference (CCDC)*, 1065–1070. <http://doi.org/10.1109/CCDC.2011.5968342>
- Zhang, X.; Huang, R.; Yao, S.; Li, G.; Zhong, L. y Wang, X. (2015). Mechanical Life Prognosis of High Voltage Circuit Breakers Based on Support Vector Machine. *Natural Computation (ICNC), 2015 11th International Conference* (pp. 749-753). Zhangjiajie
- Zhang, X. Z. X., Chen, X. C. X., Liu, H. L. H., & Zhao, B. Z. B. (2008). Application of integrated weight method and support vector machine in the comprehensive evaluation of power quality. *2008 Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*, (20060294019), 2181–2186. <http://doi.org/10.1109/DRPT.2008.4523772>
- Zhang, Y.; Ilic, M. y Tonguz, O. (2007). Application of Support Vector Machine Classification to Enhanced Protection Relay Logic in Electric Power Grids. *Power Engineering, 2007 Large Engineering Systems Conference* (pp. 31-38). Recuperado de: [http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=4437348](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4437348)
- Zhu, F. (2005). Classification of Power Quality Disturbances Using, (August), 18–21. <http://doi.org/10.3906/elk-1112-51>
- Guo-Sheng Hu, Jing Xie and Feng-Feng Zhu, “Classification of power quality disturbances using wavelet and fuzzy support vector machines,” *2005 International Conference on Machine Learning and Cybernetics*, Guangzhou, China, 2005, pp. 3981-3984 Vol. 7.
- Zhu, Y.-L.; Zhao, W.-Q.; Zhai, X.-M. y Zhang, X.-Q. (2007). A Fault Prediction Approach for Power Transformer Based on Support Vector Machine. *Wavelet Analysis and Pattern Recognition, 2007. ICWAPR '07. International Conference on*, 4, 1457–1461. <http://doi.org/10.1109/ICWAPR.2007.4421679>

