



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Doctorado en Ingeniería

Predicción a muy corto plazo de radiación solar global en zona urbana con Máquinas de Soporte Vectorial

Tesis

Que como parte de los requisitos para obtener el grado de Doctor en ingeniería

Presenta:

M. en C. José Manuel Álvarez Alvarado

Dirigido por:

Dr. José Gabriel Ríos Moreno

SINODALES

Dr. José Gabriel Ríos Moreno
Presidente

Firma

Dr. Mario Trejo Perea
Secretario

Firma

Dr. Gilberto Herrera Ruíz
Vocal

Firma

Dr. Eusebio Jr. Ventura Ramos
Suplente

Firma

Dr. Guillermo Ronquillo Lomelí
Suplente

Firma

Centro Universitario Querétaro, QRO
Diciembre 2020
México.

Dirección General de Bibliotecas UAQ

Agradecimientos

A la Universidad Autónoma de Querétaro por brindarme la oportunidad de realizar mis estudios de doctorado en esta Institución.

A la coordinación de Doctorado en Ingeniería encabezada por el Doctor Irineo Torres Pacheco. Al Doctor Gabriel Ríos por su asesoría, enseñanza en este trabajo, por el apoyo en la escritura de publicaciones científicas y por confiar en mí.

Al Doctor Eusebio Ventura por su confianza, apoyo y consejos.

Al Doctor Mario Trejo por su apoyo y asesoría en este trabajo.

A los Doctores miembros de mi sínodo, por su tiempo, dedicación, consejos y paciencia.

A mis amigos Roberto Ramos, Fernando Salas y José Salas, que son más que mis hermanos. Gracias por las enseñanzas de vida

A mis amigos de la Universidad Edson, Wilfrido y Viviana, por compartir su experiencia conmigo y por sus consejos.

A mi familia, en especial a mis papás, mi hermano Jesús, tío Antonio, tía Dorotea y mi tía Margarita, por su apoyo incondicional y las alegrías compartidas.

A Yasmín por compartir los buenos y malos momentos, por ser mi psicóloga y compañera de vida, por motivarme a dar siempre lo mejor de mí. Te lo agradezco muchísimo.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por proveer los fondos para realizar esta investigación.

Resumen

La predicción de radiación solar a corto plazo es relevante para los usuarios dedicados en la gestión, transporte y generación de la energía para hacer una eficiente planificación. Actualmente, existen modelos capaces de estimar con un mínimo grado de error esta predicción, lo que resulta conveniente en el uso de recursos meteorológicos que pueden reducir los requisitos de aprendizaje para una Machine learning. Los algoritmos de aprendizaje más comunes son las redes neuronales artificiales (ANN), la máquina de regresión vectorial (SVR) y las máquinas de soporte vectorial (SVM), siendo este último el que presenta un mejor rendimiento en comparación a los anteriores en la predicción de radiación solar. Este trabajo tiene como objetivo presentar el rendimiento de la aplicación de las SVM como modelo predictorio para estimar la radiación solar global en una zona urbana obteniendo como entradas la base de datos de una estación meteorológica intentando mejorar la predicción de los modelos actuales. El modelo creado de SVM selecciona los pesos apropiados en el diseño de los núcleos discriminatorios de datos meteorológicos que evalúan la radiación solar futura. Los resultados muestran que es posible predecir con cinco variables: temperaturas máximas y mínimas del medio, presión atmosférica, velocidad de viento y la humedad del ambiente. Los pesos son estimados para encontrar el óptimo mediante un algoritmo inteligente de búsqueda mediante la técnica de Evolución diferencial y se evalúa el error mediante el cálculo de error cuadrático medio.

Palabras Clave: Predicción nowcast, radiación solar, Machine learning, máquinas de soporte vectorial, gestión de la energía.

Abstract

The prediction of solar radiation in the short term is relevant for users dedicated to the management, transport and generation of energy to make efficient planning. Currently, there are models capable of estimating this prediction with a minimum degree of error, which is convenient in the use of meteorological resources that can reduce the learning requirements for Machine learning. The most common learning algorithms are artificial neural networks (ANN), the vector regression machine (SVR) and vector support machines (SVM), the latter being the one that presents better performance compared to the previous ones in prediction of solar radiation. This work aims to present the performance of the application of SVMs as a predictive model to estimate global solar radiation in an urban area, obtaining as inputs the database of a meteorological station, trying to improve the prediction of current models. The model created from SVM selects the appropriate weights in the design of the discriminating nuclei of meteorological data that evaluate future solar radiation. The results show that it is possible to predict with five variables: maximum and minimum temperatures of the environment, atmospheric pressure, wind speed and humidity of the environment. The weights are estimated to find the optimum through an intelligent search algorithm using the Differential Evolution technique and the error is evaluated by calculating the mean square error.

Keywords: Nowcast prediction, solar radiation, Machine learning, vector support machines, energy management.

Índice general

Resumen

Abstract

Índice

Índice de Figuras	III
Índice de Tablas	v
1. INTRODUCCIÓN	1
1.1. Plantamiento del problema	5
1.2. Justificación	8
1.3. Estructura del documento	10
2. ANTECEDENTES	12
2.1. Revisión literaria	12
2.2. El fenómeno de la radiación solar	16
2.2.1. Radiación solar global	17
2.2.2. Radiación solar difusa	18
2.2.3. Radiación solar directa	19
2.3. Estimación del potencial solar en una zona	20
2.4. La importancia de predecir la radiación solar	21
2.4.1. Predicción nowcast	22
2.4.2. Predicción a largo plazo	23
2.5. Algoritmos de predicción con Machine learning	24

2.5.1. Máquinas de soporte vectorial	25
2.6. Modelos de optimización	30
2.7. Modelos de evaluación del modelo	33
3. HIPÓTESIS	35
4. OBJETIVOS	36
4.1. Objetivo general	36
4.2. Objetivos específicos	36
5. METODOLOGÍA	37
5.1. Estudio y selección del área de estudio	38
5.2. Selección de las variables de entrada	41
5.3. Estructura de la Máquina de soportes vectorial	43
5.4. Selección de parámetros	46
6. RESULTADOS Y DISCUSIÓN	48
6.1. Adquisición de los datos	48
6.2. Estimación del recurso solar	50
6.3. Predicción de radiación solar en sitio	53
7. CONCLUSIONES	59
6. REFERENCIAS	71
8. APÉNDICE A. PRODUCTOS DEL TRABAJO DE INVESTIGACIÓN	72
8.1. Anexo 1. Artículo en revista indizada	72
8.2. Anexo 2. Artículo en revista indizada	74
8.3. Anexo 3. Artículo en revista indizada	76
8.4. Anexo 4. Colaboración Artículo en revista indizada	78

8.5. Anexo 5. Modelo de Utilidad	80
8.6. Anexo 6. Artículo en revista arbitrada	81
8.7. Anexo 7. Formación de Recurso Humano	84
8.8. Anexo 8. Participación y organizador de eventos académicos	92
8.9. Anexo 9. Cursos de formación académica	93
8.10. Anexo 10. Seminario Doctoral	93

Dirección General de Bibliotecas UAG

Índice de Figuras

1.1. Escala de predicción para la gestión de energía en una red eléctrica.	7
2.1. Componente de radiación solar difusa.	19
2.2. Componente de radiación solar difusa.	20
2.3. Relación entre horizontes de pronóstico y modelos de predicción.	22
2.4. Clasificación de aprendizaje supervisado.	25
2.5. Visualización esquemática general de un modelo SVM.	29
2.6. Diagrama de flujo del funcionamiento de la evolución diferencial.	33
5.1. Metodología general de la investigación.	37
5.2. Ubicación geográfica de las EMA en el estado de Querétaro.	41
5.3. Diagrama de flujo de la máquina de soporte vectorial propuesta.	45
5.4. Diagrama de flujo SVM + algoritmo genético.	46
6.1. Estación solarimétrica para medir componentes de radiación solar.	49
6.2. Estación meteorológica automática Querétaro.	49
6.3. Radiación solar promedio en la zona.	50
6.4. Horas solar pico por mes.	51
6.5. Estimación de producción de energía solar.	52
6.6. Configuración de la SMV para la predicción de radiación solar en sitio.	53
6.7. Resultado del entrenamiento con SVM.	54
6.8. Resultado del entrenamiento con SVM.	55
6.9. Trayectoria de la radiación solar entrenada vista desde la real.	55

6.10. Rendimiento de la predicción de radiación solar predicha contra la real.	56
6.11. Datos de validación de predicción en nowcast.	57
6.12. Datos de salida de la SVM.	57
6.13. Comparativa de los modelos de búsqueda de parámetros del modelo SVM.	58

Dirección General de Bibliotecas UAQ

Índice de Tablas

2.1. Estado del arte de las técnicas de predicción de radiación solar . .	16
5.1. Estado del arte de las técnicas de predicción de radiación solar . .	44

Dirección General de Bibliotecas UAO

INTRODUCCIÓN

En años recientes, la generación y transporte de energía son temas muy importantes para el desarrollo social y económico de cualquier nación que desea ser sustentable. Hoy en día, la demanda de combustible fósil es de un 80 % del total de la energía consumida a nivel mundial y más del 95 % se utiliza para el sector transporte (Cradden et al., 2015). El uso de estos combustibles fósiles ha sido una de las causas principales del efecto invernadero que está sucediendo en la tierra (Coady et al., 2017; Gustavsson et al., 2017,0), por lo que, actualmente, la comunidad científica se ha dado a la tarea de desarrollar nuevas tecnologías enfocadas a la generación y uso de energía eléctrica a través del recurso solar (Cecati et al., 2010; Chang et al., 2017; Álvarez-Alvarado et al., 2020).

Bajo este contexto, las empresas suministradoras de energía eléctrica deben de ser capaces de administrar la producción de energía para satisfacer el consumo en cualquier momento (Voyant et al., 2017). Es por esto que se ha apostado en la generación de nuevas técnicas para administrar la producción de energía, ya que es un factor importante para que una sociedad pueda prosperar económicamente y sin dañar al ambiente al usar energías alternativas (Suganthi and Samuel, 2012). Sin embargo, el reto está en que las energías alternativas (como la solar, eólica, por mencionar algunas), es que no son constantes y resultan difíciles de modelar. Con la finalidad de satisfacer el equilibrio entre generación

y consumo, es crucial predecir la radiación solar en instalaciones de gran capacidad de generación de energía eléctrica.

La energía solar es una fuente importante de energía renovable y limpia, actualmente en expansión en diferentes países del mundo, y con un enorme potencial para contribuir significativamente a la combinación de energías y las economías nacionales de estos países. Los datos de radiación solar precisos y fiables, especialmente en forma de radiación solar global, son de importancia indispensable en muchas aplicaciones de energía solar, tales como el diseño y supervisión del rendimiento de paneles fotovoltaicos, calentadores de aire solares, calentadores de agua solares, por mencionar algunas (Fouilloy et al., 2018). En general, se define radiación electromagnética como un modo de propagación de energía por ondas electromagnéticas, en un amplio intervalo de longitudes de onda. El espectro electromagnético está formado por el conjunto de radiaciones monocromáticas que componen la radiación electromagnética, esta radiación que llega al tope de la atmósfera procedente del Sol se denomina radiación solar extraterrestre. Si se analiza la radiación solar extraterrestre, se comprende que sufre complejos procesos de atenuación al atravesar la atmósfera, lo que provoca una disminución en la cantidad de radiación solar incidente en la superficie terrestre. La radiación solar que proviene de la dirección en que se encuentra el Sol se denomina radiación solar directa. A diferencia de esta, la radiación solar procedente de direcciones distintas a la dirección del Sol se la llama radiación solar difusa. La suma de las componentes, difusa y directa, dará lugar a la radiación solar global (Tian et al., 2018).

La predicción de la energía solar se está convirtiendo en un tema importante en el contexto de las fuentes de energía renovables y los Algoritmos de Aprendizaje Automático juegan un papel importante en este campo. La predic-

ción de la energía solar puede ser tratada como un problema de predicción de series de tiempo utilizando datos históricos (Aler et al., 2017). La estimación de la potencia de salida de los sistemas solares es necesaria para el buen funcionamiento de la red eléctrica o para la gestión óptima de los flujos de energía que se producen en el sistema solar. Antes de predecir la salida de los sistemas solares, es esencial concentrar la predicción en la irradiancia solar. La predicción de la radiación solar global se puede realizar por varios métodos; las dos grandes categorías son las imágenes de nube combinadas con modelos físicos y los modelos de aprendizaje automático (Arbizu-Barrena et al., 2017).

Un modelo de predicción esencialmente consiste en un sistema de ecuaciones lineales o no que relacionan los valores futuros de la variable a predecir con los valores presentes y pasados de la propia variable y de las variables explicativas. Antes de realizar una predicción, se debe definir el horizonte de predicción en el que el modelo deberá ser aplicado (Olatomiwa et al., 2015). Para este trabajo, se define un horizonte a muy corto plazo, o bien, un "nowcast" se puede definir como un pronóstico para el próximo período de 6 horas, basado en datos detallados de observación como radiómetros, pirheliómetros, imágenes de satélite o cámaras de cielo, entre otros. Estas predicciones son adecuadas para el funcionamiento y control de plantas poder. Para algunas aplicaciones, las predicciones de radiación solar de 0 a 180 horas, se entregan en línea, cada 6 horas (Lauret et al., 2015).

La predicción de la energía solar se está convirtiendo en un tema importante en el contexto de las fuentes de energía renovables y los Algoritmos de Aprendizaje Automático juegan un papel importante en este campo. La predicción de la energía solar puede ser tratada como un problema de predicción de series de tiempo utilizando datos históricos (Aler et al., 2017). La estimación de

la potencia de salida de los sistemas solares es necesaria para el buen funcionamiento de la red eléctrica o para la gestión óptima de los flujos de energía que se producen en el sistema solar. Antes de predecir la salida de los sistemas solares, es esencial concentrar la predicción en la irradiancia solar. La predicción de la radiación solar global se puede realizar por varios métodos; las dos grandes categorías son las imágenes de nube combinadas con modelos físicos y los modelos de aprendizaje automático (Lauret et al., 2015).

La predicción solar juega un papel importante en la investigación actualmente, ya que esta tecnología permite que la energía solar sea integrada en la red, teniendo buenos resultados al mejorar la calidad de energía suministrada a la red y en reducir los costos de los accesorios relacionados con el uso de este recurso (Xue, 2017). La combinación de estos factores ha sido la motivante para el desarrollo y diseño de modelos de un complejo campo de investigación que tiene como objetivo producir mejores predicciones del recurso solar y con ello poder predecir la potencia de salida que pueda ser generada dependiendo del tipo de tecnología utilizada y del horizonte de predicción utilizado (Renno et al., 2016).

Un modelo de predicción esencialmente consiste en un sistema de ecuaciones lineales o no que relacionan los valores futuros de la variable a predecir con los valores presentes y pasados de la propia variable y de las variables explicativas. Antes de realizar una predicción, se debe definir el horizonte de predicción en el que el modelo deberá ser aplicado (Olatomiwa et al., 2015). Para este trabajo, se define un horizonte a muy corto plazo, o bien, un "nowcast" se puede definir como un pronóstico para el próximo período de 6 horas, basado en datos detallados de observación como radiómetros, pirheliómetros, imágenes de satélite o cámaras de cielo, entre otros. Estas predicciones son adecuadas

para el funcionamiento y control de plantas poder. Para algunas aplicaciones, las predicciones de radiación solar de 0 a 180 horas, se entregan en línea, cada 6 horas (Lauret et al., 2015).

1.1. Plantamiento del problema

Los sistemas eléctricos (sistemas de energía eléctrica o sistemas eléctricos de potencia) presentan como problema característico, frente a otros sistemas de energía, el de la imposibilidad actual (desde un punto de vista práctico) de poder almacenar energía eléctrica a gran escala. Por otra parte, un sistema eléctrico fiable debe asegurar que la demanda de energía eléctrica, por parte de los usuarios, va a estar suficientemente cubierta por la generación eléctrica disponible en cada momento. Como consecuencia de esto, se hizo evidente desde los primeros momentos de puesta en funcionamiento de los sistemas de generación, transporte, reparto y distribución de energía eléctrica, la necesidad de disponer de herramientas de predicción de valores futuros de las variables que intervienen en el funcionamiento del sistema eléctrico (Jiménez, 2007).

La tecnología más novedosa y por lo tanto la más complicada de llevar a cabo es el nowcasting, la cual consiste en hacer predicciones de radiación a muy corto plazo con horizontes inferiores de una hora teniendo los valores de radiación horizontal o directa a tan pequeño plazo reside en la importancia de detectar el tipo de nubes y el movimiento que estas realizarán en caso de días con cielos cubiertos (Izgi et al., 2012). Esta escala temporal es usada en aplicaciones de plantas termosolares, las cuales necesitan predicciones de entre 5 y 30 minutos y en el control bioclimático (Cristaldi et al., 2017). Hasta la fecha se han utilizado métodos robustos en la predicción solar que trabajan de forma

eficaz solo en determinadas situaciones.

El problema con el que se encuentra normalmente esta tecnología tan reciente reside en el efecto no lineal y caótico de movimiento de las nubes; sin embargo, una serie de enfoques prometedores se han llevado a cabo en los últimos años, con lo que el campo de la investigación incipiente de la meteorología solar para la generación de predicciones ha crecido considerablemente mediante el uso de diversas áreas del conocimiento como la física atmosférica, la instrumentación solar, el aprendizaje automático, la previsión y la teoría de teledetección en su búsqueda por mejores capacidades de predicción (Ducun, 2014).

El problema actual reside en el comportamiento no lineal de las nubes en la predicción de radiación solar. Sin embargo, se ha encontrado un panorama favorable en los últimos años en el campo de investigación de la meteorología para la generación de nuevos modelos predictorios que favorezcan la integración de técnicas en el conocimiento del recurso próximo. Las nuevas técnicas recaen en la instrumentación solar, la previsión y teoría de teledirección y, actualmente, en las Machine Learning (Alizamir et al., 2020).

La fiabilidad del sistema eléctrico pasa a depender de la capacidad del sistema para acomodarse a cambios esperados e inesperados en producción y consumo ya las perturbaciones, manteniendo al mismo tiempo la calidad y la continuidad del servicio a los clientes. Entonces, el proveedor de energía debe manejar el sistema con varios horizontes temporales (Figura 1.1).

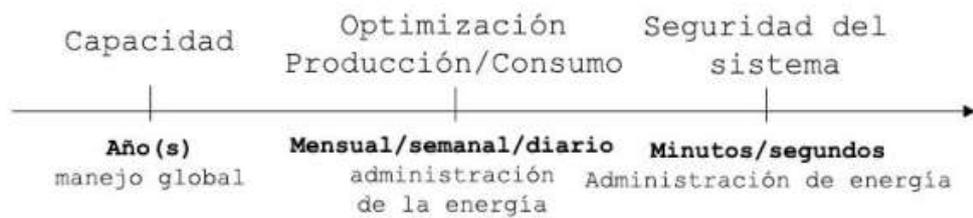


Figura 1.1: Escala de predicción para la gestión de energía en una red eléctrica.

A corto plazo, las previsiones intra-horarias son particularmente útiles para llevar a cabo operaciones en la planta solar, dar equilibrio a la red, conseguir un control automático de generación y del comercio. Actualmente, es muy difícil predecir de manera precisa la radiación solar a corto plazo, ya que implica conocer de antemano la cantidad de energía que producen las plantas solares instantáneamente y esto sería de gran ayuda a la hora de evitar problemas de abastecimiento de la línea o de evitar excedentes de energía (Egea, 2016).

Las previsiones para horizontes temporales de más largo plazo son de interés para los servicios públicos y estratégicos para la unidad de compromiso, la programación y para mejorar el control en dicha área (Ghimire et al., 2018) . A pesar de su creciente popularidad, el modelo de ANN tiene sus propios desafíos, por ejemplo, el algoritmo retro propagación puede tener dificultad en el entrenamiento de los datos de entrada debido a Belaid and Mellit (2016):

- La afinación iterativa de los parámetros necesarios para las neuronas ocultas no siempre produce una única solución (global).
- Tiene una respuesta lenta debido a su algoritmo de aprendizaje basado en gradientes.
- Requiere más tiempo de ejecución.

A pesar de la flexibilidad del modelo SVM en el manejo de insumos no lineales, los modelos pueden encontrar dificultades debido a la respuesta no estacionaria para sus datos de entrada de entrenamiento que varían sobre frecuencias amplias (por ejemplo, hora, día a día). En el caso del ciclo diario o de la estacionalidad, la ausencia de datos de insumo-producto y un esquema de procesamiento pueden plantear desafíos para el modelo debido a su incapacidad para manejar los datos atmosféricos no estacionarios. El advenimiento de los modelos híbridos en los que se utiliza una técnica de procesamiento previo (por ejemplo, transformación en olas) ha ganado prominencia (Deo et al., 2016).

La predicción nowcasting de la radiación solar en zonas urbanas con support vector machine reduce el error de predicción que se genera en sistemas a base de evaluación de variables meteorológicas debido al comportamiento no lineal de dichas variables en las zonas urbanas.

1.2. Justificación

La motivación del presente proyecto surge de la necesidad de obtener y mejorar la generación de energía limpia y barata a través de energías renovables, como lo es el caso del recurso de la radiación solar a nivel de superficie terrestre, así como su predicción, debido a que hoy en día, se ha generado un gran interés para las energías renovables y para distintas aplicaciones industriales o ecológicas.

En el ámbito de las energías renovables, el uso óptimo de la energía solar implica contar con datos de la radiación solar en superficie que ayuden tanto, en la selección de emplazamientos para instalaciones de energía solar, como en su

etapa de diseño (dimensionar la producción) y, finalmente, en su explotación. En este último caso, la observación y la predicción es útil para el mercado energético, la planificación y gestión de la energía (como las plantas térmicas solares). A pesar de la importancia estratégica de contar con datos de la radiación, especialmente los observados por sensores de IS en superficie (los que mejor captan esta variable), estos no siempre están disponibles para los lugares de interés ni con la resolución espacial y temporal deseada. Esta limitación se une a la necesidad de disponer de predicciones a corto plazo de la radiación solar que ayuden a la planificación y gestión de la energía.

La estimación de la producción de energía eléctrica en el futuro también implicará la previsión de la radiación solar, que sólo ayuda a optimizar la integración de la energía solar en las redes eléctricas, además de garantizar la sostenibilidad y el rendimiento comercial favorable en los mercados de la electricidad (Yadav and Chandel, 2014). Los modelos de predicción son atractivos para organismos gubernamentales y no gubernamentales (Gutierrez, 2014). Es por eso, que un sistema de predicción a corto plazo en la ciudad de Querétaro, como caso de estudio, ayudará a conocer la radiación futura a corto plazo debido al inminente cambio hacia la utilización de energías renovables. Un modelo confiable es una gran estrategia para que los tomadores de decisiones lleven a cabo los proyectos de energía renovable o de ampliar las redes de observación solar con la propuesta de una máquina de soporte vectorial (SVM) como modelo predictivo.

Las SVM se relacionan con las redes de regularización y ofrece un avance sobre el modelo de RNA. Se basa en la teoría del aprendizaje estadístico que adoptan métodos mínimos cuadrados para resolver el problema a las soluciones menos cuadradas a través de un conjunto de ecuaciones lineales basadas en la minimización del riesgo estructural. Por lo tanto, el modelo SVM puede evitar el

ajuste excesivo de los datos de entrenamiento, no requiere un ajuste iterativo de los parámetros del modelo tiene mejor generalización, requiere pocos núcleos y tiene buen desempeño (Salcedo et al., 2016). Para determinar la elección adecuada del modelo de predicción con máquina de soporte vectorial, las variables climáticas, tales como velocidad del viento, dirección del viento, temperaturas máximas y mínimas diarias en lapsos de 10 minutos, además del porcentaje de nubosidad deben ser identificados para el diseño del algoritmo de predicción que mejor estime la radiación solar futura. Éste modelo puede evitar el ajuste excesivo de los datos de entrenamiento, no requiere un ajuste iterativo de los parámetros del modelo, tiene mejor generalización, requiere pocos núcleos y tiene buen rendimiento (Deo et al., 2016).

1.3. Estructura del documento

El capítulo 1, presenta la introducción general del trabajo de investigación, el planteamiento del problema, la justificación y la estructura del documento.

En el capítulo 2, se presentan los Antecedentes y el estado del arte de la aplicación de técnicas de predicción mediante el uso de Machine learning para la predicción de radiación solar. Se identifican sus fortalezas y retos.

El capítulo 3 muestra la Hipótesis de la investigación desarrollada.

El capítulo 4 muestran el objetivo general y los objetivos específicos del trabajo de investigación.

El capítulo 5, muestra la metodología propuesta en el estudio de la integración de las Machine Learning con respecto a las variables involucradas en el entrenamiento. Se describen los métodos de predicción, de optimización y los

criterios estadísticos para la interpretación de resultados

En el capítulo 6 se muestran los resultados obtenidos en la predicción de la radiación solar en su componente global y la validación por los modelos estadísticos.

En el capítulo 7, se presenta las principales conclusiones de esta investigación y se sugieren los trabajos futuros.

Dirección General de Bibliotecas UFRQ

ANTECEDENTES

Para una exitosa optimización de integración, dimensionamiento y planeación de granjas dedicadas al aprovechamiento del recurso solar, se necesita la predicción inmediata de energía solar. Los enfoques de modelado estadístico y de aprendizaje automático proporcionan una solución superior para la predicción inmediata solar en comparación con los modelos deterministas basados en la Física. En este capítulo, se revisa el estado del arte de modelos predictorios y se enfatizan los grandes aportes. Así mismo, se definen las consideraciones teóricas que son abordadas para realizar este trabajo.

2.1. Revisión literaria

Sanfilippo et al. (2016) describieron un enfoque novedoso para predecir el recurso solar por medio de adaptar múltiples modelos de clasificación supervisada como regresión de soportes vectoriales (SVR), persistencia (PER) y modelos autorregresivos de orden 3 y 11. Este modelo presenta una mejora en la puntuación de habilidad relativa (rSS) del 44,92% sobre el modelo de referencia (PER) y del 19,06% sobre el modelo de mejor rendimiento (AR11), y tienen solo un 1,15% más de tasa de error (rRMSE) que los resultados de conocimiento perfecto. Además, el enfoque de modelado múltiple superó consistentemente a

cualquiera de los cuatro enfoques de los modelos SVR, PER, AR3, AR11 por separado.

Cheng (2016) propone un modelo mediante la fusión de un filtro Kalman y un predictor de SVM para beneficiarse de las ventajas de ambas técnicas. El filtro de Kalman está diseñada para lidiar con eventos de desaceleración para una predicción más precisa de la radiación solar mediante una función de sistema adaptativo variable en el tiempo obtenida por el modelo de regresión. Los errores obtenidos por este modelo se encuentran en un rango del 5 y 8% de error absoluto medio (MAE), demostrado que el diseño de la matriz del sistema fijo variable en el tiempo es útil para mejorar el resultado de la predicción del filtro de Kalman.

Lou et al. (2016) crearon un algoritmo de aprendizaje automático para predecir la irradiancia difusa horizontal del cielo y realizar un análisis de sensibilidad para las variables meteorológicas para predecir la radiación solar difusa. Las variables de entrada al modelo predictorio incluyeron el índice de claridad obtenido de la irradiancia solar horizontal global, altitud solar, temperatura del aire, cobertura de nubes y la visibilidad. El modelo propuesto sería apropiado para estimar la radiación solar difusa a largo plazo, estudiar el cambio climático con un error inferior a 21.5 W, equivalentes a una regresión lineal (R^2) de 8% de error.

Dentro de la literatura, se han encontrado también nuevas técnicas de predicción utilizando imágenes de satélite y modelos Machine Learning. Jang et al. (2016) propone un modelo de predicción de energía solar basado en imágenes de satélite y un esquema de aprendizaje de máquina de soporte vectorial (SVM). Los vectores de movimiento de las nubes se pronostican utilizando imágenes de satélite de vectores de movimiento atmosférico (AMV). Se analizan las imágenes obtenidas por satélite históricas de 4 años para configurar una gran cantidad de

conjuntos de datos de entrada y salida para el aprendizaje de SVM. El modelo de predicción propuesto basado en SVM muestra la mayor precisión de predicción, en comparación con otros modelos de predicción, como las series de tiempo convencionales y los modelos, identificando los valores de error cuadrático medio (RMSE) y R^2 de 44.1390 y 0.9420, respectivamente.

Deo et al. (2016) presentaron un modelo de máquina de soporte vectorial acoplado a wavelets para la predicción de incidentes solares globales utilizando un conjunto de datos meteorológicos limitados para la ciudad de Brisbane, Australia. Los datos se descompusieron en su subserie de wavelets mediante un algoritmo de transformación discreta y se resumieron para crear nuevas series con una aproximación y cuatro niveles de detalle utilizando la wavelete Daubechies-2. Este modelo híbrido obtuvo como resultado una aproximación de $R = 0.965$. Las variables de entrada usadas en este modelo son: variables como las horas de sol St , temperatura máxima T_{max} , temperatura mínima T_{min} , evaporación E , precipitación P y velocidad del viento U para el pronóstico diario de la radiación solar incidente global (R_n)

Yao et al. (2018) desarrolla un modelo para estimar la radiación solar global en una horizontal. Se proponen superficies en base a una máquina de vectores de soporte (SVM) utilizando como variable de entrada un índice que indica la calidad del aire para evaluar el rendimiento de esta técnica. En comparación con los modelos existentes, como las redes neuronales, el modelo propuesto en este documento pueden mejorar la precisión de los modelos de radiación solar global si se utiliza AQI como parámetro de entrada adicional demostrando que el valor $RMSE$ se reduce de 0,114 a 0,102 y el valor R^2 asciende de 0,848 a 0,876.

Bhola and Bhardwaj (2019) muestra la aplicación de un modelo de regresión de soporte vectorial (SVR) para la estimación de la radiación solar horizontal

global. El modelo evalúa el rendimiento del modelo SVR con diferentes combinaciones de parámetros meteorológicos como temperatura ambiente máxima y mínima (T_{max} y T_{min} , respectivamente), humedad (H), presión atmosférica (P), humedad relativa (E_r), número de días (N_d) y la velocidad de viento (w_s). Los datos de tres años desde 2009-2011 se adquieren del Instituto Nacional de Energía Solar (NISE) Gurugram, India. Luego del análisis de los resultados, se encontró que la temperatura es el parámetro más importante junto con la presión atmosférica, la humedad relativa, el número de días y la velocidad del viento. De acuerdo con la métrica de rendimiento para la estimación es la raíz del error cuadrático medio (RMSE) indica un índice de 14.3 que es significativamente menor en comparación con otras técnicas de vanguardia como el modelo Hidden Markov y las redes neuronales artificiales, siendo así un modelo superior.

Fan et al. (2020) propuso tres nuevas SVM híbridas con algoritmo de optimización de enjambres de partículas (SVM-PSO), algoritmo de murciélagos (SVM-BAT) y algoritmo de optimización de ballenas (SVM-WOA) para predecir radiación solar diaria en zonas urbanas. Los resultados mostraron que los modelos con ozono (O_3) produjeron estimaciones de radiación solar diarias más precisas que aquellos sin parámetros de contaminación del aire, con disminuciones relativas promedio en la raíz con una desviación cuadrática media (RMSD) de 11,1%, 10,0% y 10,4% para los modelos basados en la duración del sol, respectivamente

Tabla 2.1: Estado del arte de las técnicas de predicción de radiación solar

Autor	Año	Modelo de predicción	Horizonte de predicción	Validación
Sanfilippo	2016	Vector de regresión lineal y modelado auto regresivo	Diario	RMSE
Cheng et al.	2016	Filtro Kalman y predictor de regresión	10 - 20 min	RMSE
Lou	2016	Machine Learning basado en el algoritmo de Boosted Regression Tree (BRT)	Anual	MAE
Jang et al.	2016	Máquina de soporte vectorial (SVM)	60 min	RMSE, R ²
Deo et al.	2016	SVM-Wavelete	Mensual	R ²
Yao et al.	2018	Máquina de soporte vectorial	10 min	RMSE, R ²
Bhola and Bhardwaj	2019	Regresión de soportes vectoriales (SVR)	5 min	RMSE
Fan et al.	2020	SVM-algoritmos de optimización	diario	RMSD

2.2. El fenómeno de la radiación solar

Para la estimación de la radiación solar, es importante conocer todo el fenómeno, partiendo de la definición del sol, el cual es una estrella en cuyo interior tienen lugar una serie de reacciones que producen una pérdida de masa que se transforma en energía. Esta energía liberada del sol se transmite al exterior mediante la denominada radiación solar. La irradiancia solar es la magnitud empleada para indicar el valor de la radiación incidente en una superficie. En el caso del Sol, se define como la energía solar recibida por cada m² en un segundo (FernándezBalbuena, 2011). La intensidad de la radiación solar que llega a la parte exterior de la atmósfera depende de la distancia entre la tierra y el sol. Esa distancia no es constante, sino que el curso de la órbita de nuestro planeta describe una trayectoria elíptica y que su longitud varía entre kilómetros; de aquí se puede afirmar que el valor de la irradiancia fluctúa entre 1.47x10⁸ y 1.52 x10⁸ km , el valor medio 1.353W m² de dicha irradiancia se le conoce co-

mo constante solar (González, 2012). Es variable durante el año en un ± 3 por ciento por las causas descritas de la órbita terrestre. Otro elemento que influye sobre la radiación solar el factor denominado “masa de aire” (AM), y varia con el ángulo cenital del sol, de la distancia tierra-sol y de las condiciones atmosféricas y meteorológicas. La radiación solar alcanza los niveles más altos antes y después del mediodía. Las nubes, la lluvia y la contaminación atmosférica como partículas y ozono absorben el UV y disminuyen su intensidad a nivel del suelo (Serrano Jareño, 2013). La radiación solar, vista como un conjunto, está conformada principalmente por tres componentes:

- Radiación solar global.
- Radiación solar difusa.
- Radiación solar directa.

2.2.1. Radiación solar global

En 1971, Reddy presentó un modelo más complejo para estimar la irradiación global diaria total (H_g) (Ecuación (2.1)). Este modelo introdujo una mejora notable, incluyendo en su cálculo las horas de sol diarias (n), la duración media del día durante el mes (N), la relación de días de lluvia (J), la humedad relativa (R) y la relación entre la longitud del día y la latitud (Z)

$$H_g = Z \left[\left(1 + 0.8 \frac{n}{N} \right) \frac{(1 - 0.2J)}{R} \right] \quad (2.1)$$

El modelo de Reddy supuso una mejora significativa ya que introdujo la climatología como variable para estimar la radiación global de un lugar,

pero carecía de formulaciones específicas para el cálculo de la irradiación solar directa y difusa (Gutiérrez-Trashorras et al., 2018).

2.2.2. Radiación solar difusa

La componente de radiación solar difusa es aquella que donde las partículas y moléculas en el aire interceptan la radiación, haciendo que se disperse en la atmósfera. Esta componente proviene de las nubes y su comportamiento es no direccional con distribución uniforme. Esta radiación se ve afectada por los gases y las partículas, lo que hace que se disperse en el sitio. La radiación solar difusa genera un problema en la generación eléctrica por paneles solares fotovoltaicos, disminuyendo su capacidad de generación, es decir, que en la radiación solar, las nubes absorben toda la energía incidente y la vuelven a emitir Jiang (2009).

la difusa del cielo y la reflejada en el suelo difusa o la reflejada que alcanzan las superficies del sistema después de múltiples reflexiones entre el suelo, las nubes y la atmósfera son los componentes principales de la irradiación difusa. Es difícil estimar con claridad, e incluso obtener, datos de radiación solar difusa en México, debido a que las estaciones meteorológicas solo miden la componente global horizontal de la radiación solar. ero a pesar de este hecho, la precisión del componente difuso es crucial para estimar la entrada a los sistemas. Sin embargo, estimar el radiación difusa es simple, y y la precisión de estas estimaciones es sustancialmente mayor que las estimaciones de los componentes difusos por medio de la Ecuación 2.2 Rusen and Konuralp (2020); Karaveli and Akinoglu (2018):

$$H_{dir} = H_g - H_d \quad (2.2)$$

donde H_{dir} es la radiación solar directa, H_g es la radiación solar global y H_d es la radiación solar difusa. La Fig. 2.1 muestra la trayectoria de la radiación solar difusa hacia un sistema de captación.

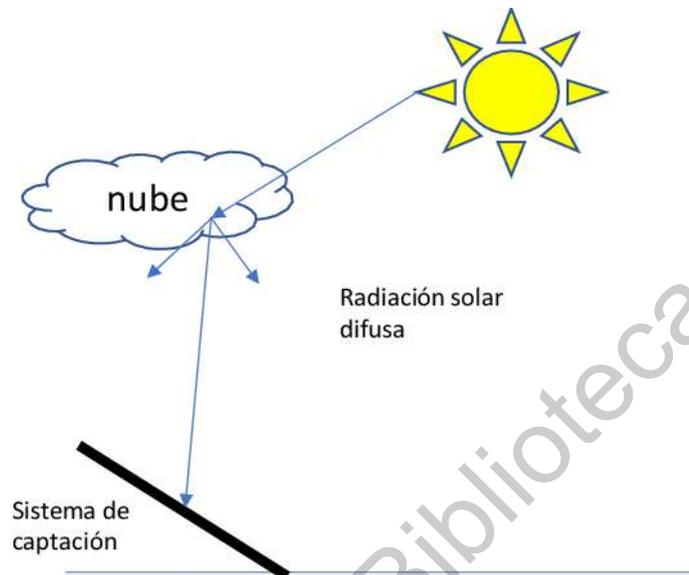


Figura 2.1: Componente de radiación solar difusa.

2.2.3. Radiación solar directa

La radiación solar directa es la que llega directamente del sol, es una radiación que tiene una dirección bien definida, es decir que viaja en línea recta asía el sistema de captación, esta puede reflejarse y concentrarse para su utilización. La Fig. 2.2 muestra la trayectoria del as de luz con la componente de la radiación directa sin refractarse.

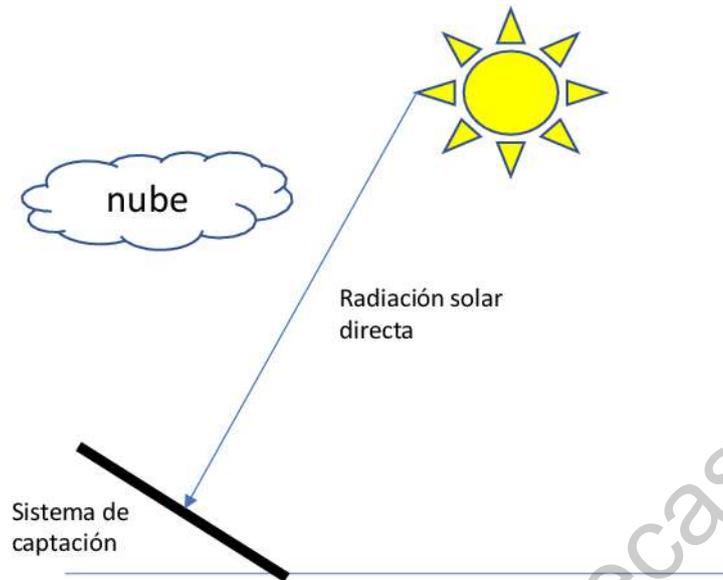


Figura 2.2: Componente de radiación solar difusa.

2.3. Estimación del potencial solar en una zona

El recurso solar disponible puede calcularse directamente a partir de los datos Rad de radiación solar global, medidos en AWS en la superficie de la tierra (Umar y Wamuziri 2016). La evaluación de los recursos solares es menos complicada que los recursos eólicos debido a que depende solo de menos variables (Vergara-Barrios et al., 2014) y algunos modelos incluso utilizan imágenes de satélite para calcular la producción de energía solar (Almasoud and Gandayh, 2015). Las horas pico de sol (*SPH*) se definen como el número equivalente de horas por día con un nivel de radiación constante de al menos $1000 \text{ W} = \text{m}^2$ (Siddiqui et al., 2018). La Ecuación 2.3 muestra la expresión para obtener la SPH de un día Hossain et al. (2016).

$$SPH = \frac{1}{1000} \sum_i^N (Rad_i) \quad (2.3)$$

La producción de energía solar estimada mensual SEP se obtiene multiplicando SPH con el solar promedio de radiación según la Ecuación 2.4. (Keyhani, 2016):

$$SEP = SPH \times \frac{1}{1000} \sum_i^n (Rad_i) \quad (2.4)$$

donde n es el número de datos de la radiación solar Rad_i .

2.4. La importancia de predecir la radiación solar

La estimación de la potencia de salida de los sistemas solares es necesaria para el buen funcionamiento de la red eléctrica o para la gestión óptima de los flujos de energía que se producen en el sistema solar. Antes de predecir la salida de los sistemas solares, es esencial concentrar la predicción en la irradiancia solar. La predicción de la radiación solar global se puede realizar por varios métodos. De acuerdo a la literatura, la exactitud de un modelo de predicción depende principalmente de los horizontes de tiempo (Lauret et al., 2015).

Para el desarrollo de cualquier modelo de predicción solar se debe contemplar, desde el primero momento de diseño, el horizonte de predicción, esto es, el periodo de tiempo (contabilizado desde un instante determinado en que realizamos la predicción), que determina el momento futuro para el que realizamos las predicciones. El mayor inconveniente es su carácter lineal, lo cual dificulta que se pueda modelar de manera adecuada todos los problemas (Arbizu-Barrena et al., 2017; Zeng and Qiao, 2013). Los modelos son muy sensibles a observaciones inusuales, lo que obliga a revisar la serie temporal para detectarlos y corregirlos antes de diseñar el modelo de predicción (Ducun, 2014). La

Fig. 2.3 muestra la relación de los horizontes temporales y los modelos aplicados para predicción.

	Intra-horario	Intra-día	Mayor a un día
Horizonte de predicción	15 – 120 min	1 – 6 h	1 – 3 días
Se relaciona Con:	Eventos rampa	Pronóstico siguiente	Programación de transmisión
Modelos de predicción	Imágenes por satélite / series temporales		Métodos numéricos de predicción

Figura 2.3: Relación entre horizontes de pronóstico y modelos de predicción.

2.4.1. Predicción nowcast

El horizonte de predicción va desde los 15 minutos hasta unas horas, no existiendo unanimidad en su valor (Sanfilippo et al., 2016). A corto plazo, las previsiones intra-horarias son particularmente útiles para llevar a cabo operaciones en la planta solar, dar equilibrio a la red, conseguir un control automático de generación y del comercio. Actualmente, es muy difícil predecir de manera precisa la radiación solar a corto plazo, ya que implica conocer de antemano la cantidad de energía que producen las plantas solares instantáneamente y esto sería de gran ayuda para evitar problemas de abastecimiento de la línea o de evitar excedentes de energía (Paulescu and Paulescu, 2019). En este horizonte, los modelos estadísticos que mejor desempeño muestran son aquellos que usan imágenes de satélite con una mayor exactitud en predicciones nowcasting (Zhang et al., 2018; Gallucci et al., 2018) y los modelos estadísticos para analizar

las series de tiempo de radiación solar, como los Numerical Weather Prediction (NWP) (Lima et al., 2016; Lorenz et al., 2012; Tiwari et al., 2018). Así mismo, en los últimos años, se han realizado varias investigaciones en el uso de Machine Learning (ML) para la predicción de radiación solar usando las máquinas de soporte vectorial (SVM) las que muestran un mejor rendimiento en el análisis de clasificación y regresión en las series de tiempo (Sun and Zhang, 2017; Eseye et al., 2018).

2.4.2. Predicción a largo plazo

Predicciones a largo plazo: corresponden a un horizonte por encima de las 48 o 72 horas, llegando a un límite de 7 días. Cuanto mayor sea el horizonte, mayores son los errores de predicción, resultando hoy en día difícil de realizar predicciones fiables de variables atmosféricas por encima de esos 7 días (Notton et al., 2019; Yesilbudak et al., 2018; Bae et al., 2016). Los horizontes temporales representan el análisis previo a la predicción, ya que, como se ha observado en la literatura, las ML son capaces de demostrar que son la mejor alternativa en el análisis de datos en series temporales. Sin embargo, la necesidad de disminuir la corrección del error, se han modificado para dar paso a modelos híbridos de modelos de regresión de las ML usando algoritmos inteligentes de búsqueda debido a que requieren una selección precisa de sus parámetros para mejorar su rendimiento (Zendehboudi et al., 2018; Li et al., 2016).

Actualmente existe mucha información publicada en revistas acerca de la predicción de radiación solar con ML, sin embargo, es necesario mostrar una revisión del estado del arte en las técnicas de predicción con el uso de algoritmos de búsqueda inteligentes que permitan mejorar la predicción en diferentes

horizontes. Este artículo muestra una revisión del estado del arte enfocando únicamente a la aplicación de modelos de Machine Learning optimizados mediante un algoritmo de búsqueda inteligente. Se revisan a detalle los resultados de los autores y se evalúa las mejores condiciones para realizar modelos híbridos para la predicción de radiación solar.

2.5. Algoritmos de predicción con Machine learning

Una machine learning (ML) se define generalmente como el proceso de aprendizaje para convertir la experiencia en experiencia de conocimiento. Por ejemplo, se dice que un programa de computadora aprende de la experiencia E con respecto a T y alguna medida de desempeño P Y si este desempeño en T medido por P mejora la experiencia E (Shalev-Shwartz and Ben-David, 2014). Las técnicas de machine learning, que integran sistemas de inteligencia artificial, buscan extraer patrones aprendidos de datos históricos en un proceso conocido como entrenamiento o aprendizaje para posteriormente realizar predicciones sobre nuevos datos que serán una predicción del comportamiento del fenómeno (Barboza et al., 2017; Christodoulou et al., 2019; Mao et al., 2019). Según la literatura, hay dos técnicas específicas principales que utiliza ML para modelar algoritmos para aprender información directamente a partir de los datos adquiridos (Bao et al., 2019): aprendizaje supervisado que utiliza desde datos actuales a datos anteriores para pronosticar eventos (Shami and Verhelst, 2007; Jiang et al., 2020) y no supervisado aprendizaje que analiza los patrones a partir de datos no clasificados y deduce una función para describir el comportamiento del sistema (Saravanan and Sujatha, 2018). La Fig. 2.4 muestra la síntesis de estos métodos de aprendizaje.

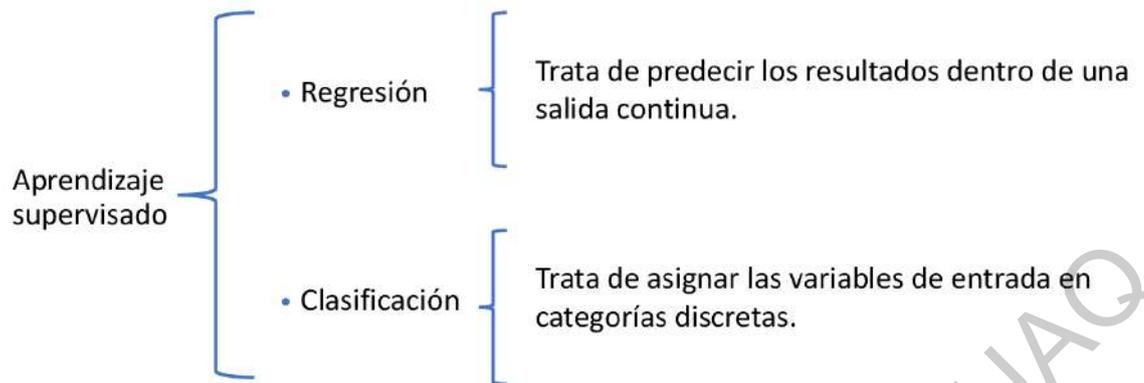


Figura 2.4: Clasificación de aprendizaje supervisado.

La estimación de la producción de energía eléctrica en el futuro también implicará la previsión de la radiación solar, que sólo ayuda a optimizar la integración de la energía solar en las redes eléctricas, además de garantizar la sostenibilidad y el rendimiento comercial favorable en los mercados de la electricidad (Yadav and Chandel, 2014). Los modelos de predicción son atractivos para organismos gubernamentales y no gubernamentales (Gutierrez, 2014).

2.5.1. Máquinas de soporte vectorial

La base teórica de SVM es la teoría del aprendizaje estadístico, más precisamente, SVM es una realización aproximada de la minimización del riesgo estructural. Según la teoría del aprendizaje estadístico, el riesgo real de estimación de regresión está relacionado con el riesgo empírico y el rango de confianza. El riesgo empírico está relacionado con la muestra de entrenamiento, y el rango de confianza está relacionado con la dimensión VapnikChervonenkis (dimensión VC) de la máquina de aprendizaje y el número de muestras de entrenamiento. Cuando estos dos factores son pequeños, es decir, no solo el riesgo empírico es pequeño, sino también la dimensión de la CV.

La máquina del vector de la ayuda es otra técnica de aprendizaje basada en la máquina del kernel usada en tareas de la clasificación y problemas de la regresión introducidos por Vapnik en 1986. La regresión vectorial de soporte (SVR) se basa en la aplicación de máquinas vectoriales de apoyo a los problemas de regresión (Lauret et al., 2015). Este método se ha aplicado con éxito a las tareas de pronóstico de series temporales.

El modelo SVM clásico pertenece a una clase de métodos ML basados en núcleos que se utilizan para resolver los problemas de regresión mediante un conjunto de variables predictoras que están intrínsecamente relacionadas con la variable objetivo. Para resolver un problema no lineal, una variable de entrada que corresponde a la variable predictor se mapea de forma no lineal en un espacio de entidad de alta dimensión y se correlaciona linealmente con la variable objetivo para formalizar el modelo SVM (Ecuación 2.5):

$$R_n = f(x) = \omega \cdot \phi(x) + b \quad (2.5)$$

Donde ω es el vector ponderado, b es la constante, $\phi(x)$ denota una función de mapeo que se utiliza en el espacio de características. Los coeficientes ω y la constante b se estiman por minimización mediante las Ecuaciones 2.6 y 2.7:

$$Reg(f) = C \frac{1}{N} \sum_{i=1}^N x_{i=1} = L_e(f(x_i), y_i) + \frac{1}{2} \|w\|^2 \quad (2.6)$$

$$L_e(f(x_i), y_i) = \begin{cases} \text{si } f(x), y - \epsilon & \text{for } f(x), y \geq \epsilon \\ 0 & \text{otherwise} \end{cases} \quad (2.7)$$

Donde C y ϵ son los parámetros prescritos del modelo. El primer término $L_\epsilon(f(x_i), y_i)$ es llamado el ϵ -ésima función de pérdida y el y_i es la radiación solar en el periodo i . Esta función indica que los errores que cayeron debajo de ϵ no serán penalizados y el término $C \frac{1}{N} \sum_{i=1}^N L_\epsilon(f(x_i), y_i)$ es el error empírico del modelo del SVM. El término $\frac{1}{2} \|w\|^2$ mide la suavidad de la función, C evalúa el equilibrio entre el riesgo empírico y la suavidad y el positivo. Las variables de holgura ς y ς^* representan la distancia desde los valores reales a los valores de los límites correspondientes a lo largo de ϵ . La Ecuación 2.7 se transforma de acuerdo a las Ecuaciones 2.8 y 2.9:

$$\text{minimiza } \frac{1}{2} \|w\|^2 + C \frac{1}{N} \sum_{i=1}^N (\varsigma_i + \varsigma_i^*) \quad (2.8)$$

$$\text{sujeto a } \begin{cases} y_i - (\langle w, x_i \rangle + b) \geq \epsilon + \varsigma_i \\ \langle w, x_i \rangle + b - y_i \leq \epsilon + \varsigma_i \\ \varsigma_i, \varsigma_i^* \geq 0 \end{cases} \quad (2.9)$$

Después de aplicar Lagrange y para óptimas condiciones, se obtiene una función de regresión no lineal, como se muestra en la Ecuación 2.10:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i - x) + b \quad (2.10)$$

Donde α_i, α_i^* son los multiplicadores de Lagrange. Usando la condición de Kuhn-Tucker (KKT), solo un limitado número de coeficientes no será cero entre los coeficientes α_i y α_i^* . Los puntos de datos relacionados, que se denominan "vectores de soporte", estarán más próximos a la superficie de decisión (o hiperplano). El término $k(x_i - x)$ es la función del kernel que describe el producto

interno en el espacio de entidad de dimensión, como se muestra en la Ecuación 2.11:

$$K(x_i - x) = \sum_{i=1}^D \phi_i(x) + \phi_i(y) \quad (2.11)$$

La Ecuación 2.12 estipula que la función simétrica del núcleo es necesaria para satisfacer la condición de Mercer que corresponde a un producto escalar en el espacio de características (Boser et al., 1992). Entre las diferentes funciones del núcleo utilizadas (por ejemplo, lineal, polinomial, sigmoide), se utiliza función de base radial (RBF) (Suykens et al., 2002) en este estudio a saber:

$$K_{rbf}(x, x_i) = \exp\left(-\frac{(x_i - x_j)^2}{2\sigma^2}\right) \quad (2.12)$$

Donde σ es el peso del kernel y x_i y x_j son las entradas a la i -ésima y j -ésima dimensiones, respectivamente. Un conjunto de kernels alternativos basados en la ecuación lineal $\langle x_i, x_j \rangle$, la ecuación polinomial $K_d(x_i, x_j) = (x_i, x_j + 1)^d$ con grado d y la ecuación sigmoide $K(x_i, x_j) = \tanh(kx_i + x_j + c)$ con c y k definidas como el centro y el ancho, respectivamente (Kaestner, 2013) también podría ser utilizado. Sin embargo, la ecuación K_{rbf} es elegida debido a que es la función más común y ofrece un buen rendimiento que está relacionado con su soporte compacto y el simple requisito de seleccionar sólo un solo parámetro, la anchura del núcleo (Goyal and Goyal, 2011; Goyal, 2014). RBF kernel es computacionalmente eficiente ya que su formación sólo necesita soluciones de un conjunto de ecuaciones lineales en lugar de un exigente problema de programación cuadrática (Olatomiwa et al., 2015). Una tarea importante para el modelador es optimizar el factor de regularización C y el ancho del núcleo σ . En particular, la magni-

tud de σ (anchura del núcleo) determina el área aproximada de influencia de los vectores de soporte dentro del espacio de optimización de la característica y C equilibra el encaje en la etapa de entrenamiento del modelo y la generalización de los datos en la etapa de implementación. Para lograr el mejor rendimiento, es necesario ajustar correctamente los parámetros C y σ (Zeng and Qiao, 2013). La Fig. 2.5 describe una vista general a manera de esquema del modelo SVM .

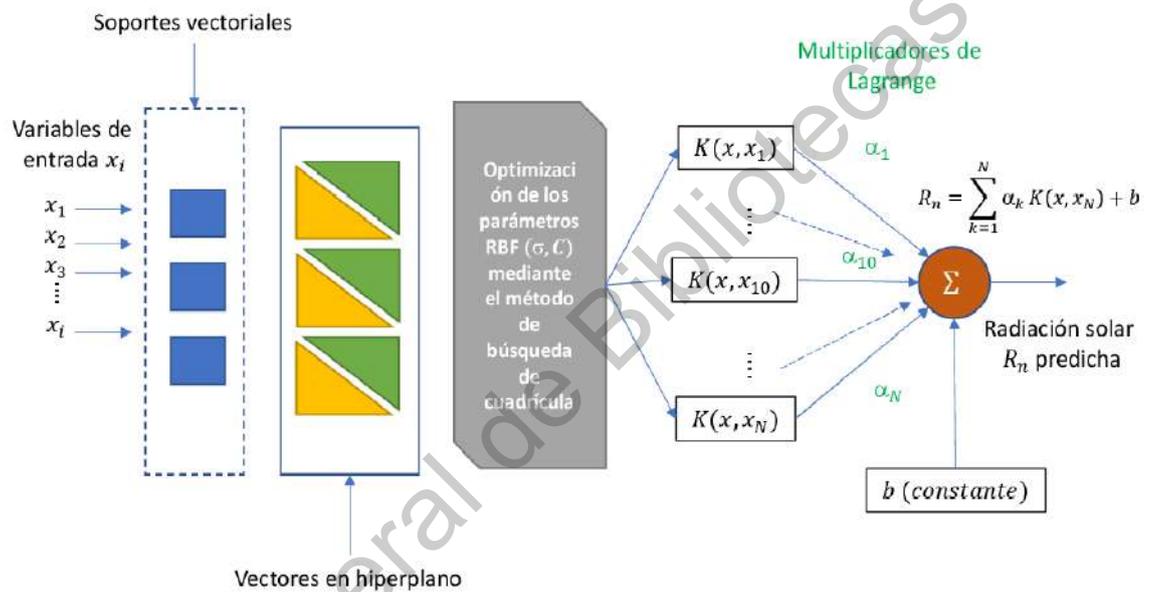


Figura 2.5: Visualización esquemática general de un modelo SVM.

De acuerdo con la Figura 2.5, Supongamos que tenemos un conjunto de variables predictoras (de entrada) relacionadas con la radiación solar. Los puntos de referencia se pueden escribir como H_g . Los datos meteorológicos tienen n variables y la variable objetivo está compuesta por la serie de tiempo de radiación solar, R_n y t ($t = 1, \dots, N$), y la entrada meteorológica, x_t es $N \times (m - 1)$ matriz. . En este artículo, $x_t(i)$ es la i -ésima columna ($i = 1, \dots, M - 1$) de la matriz de entrada x_t para representar la serie de tiempo de la i -ésima variable meteorológica. La $x(i)(t)$ representa el valor de x_t en el tiempo t y el vector predictor, $x = [St,$

Tmax, Tmin, U, E y P] que se adquieren de las mediciones en las respectivas estaciones meteorológicas. El propósito del modelo SVM es extraer el conjunto óptimo de patrones (características predictivas) contenidos en la serie de tiempo x para pronosticar la variable objetivo, R_n

2.6. Modelos de optimización

El algoritmo genético es una herramienta de búsqueda numérica que opera de acuerdo con procedimientos que se asemejan a los principios de la selección natural y la genética. Estudios previos aprovecharon el algoritmo genético acoplado a ANN (ANN-GA) para generar las variables operativas óptimas globales para los procesos estudiados

El algoritmo de Evolución Diferencial propuesto alrededor del año 1995 para problemas de optimización (Storn and Price, 1997) surgió en un intento de mejorar otro algoritmo que se basaba en Algoritmos Genéticos de Goldberg (Goldberg and Holland, 1988) y Recocido Simulado (Coello, 1994). DE es un algoritmo evolutivo basado en poblaciones. El algoritmo DE se basa en tres operadores, mutación, cruzamiento y selección que a diferencia de los operadores con igual nombre de Algoritmo Genéticos (Goldberg and Holland, 1988), están basados en operaciones con vectores. La selección de DE se basa en las ventajas que presenta sobre los algoritmos genéticos, de los cuales se reporta una aplicación al diagnóstico de fallos en [20]: estructura simple, mayor velocidad y robustez (Storn and Price, 1997).

Estas características resultan adecuadas al enfocar problemas donde se requiera una detección del fallo en tiempo real. Otro criterio para seleccionar DE

es el éxito que ha tenido su aplicación a la solución de varios problemas inversos de estimación de parámetros en ingeniería (Chen et al., 2017). Las poblaciones consisten en vectores de números reales con dimensión D, el tamaño de la población se ajusta mediante el parámetro NP. La población inicial se genera de manera aleatoria como se muestra a continuación en la Ecuación 2.13.

$$X = x_m^{in} + rand(0, 1)(x_m^{ax} - x_m^{in}) \quad (2.13)$$

En cada generación (población), cada vector de la población actual se convierte en un vector objetivo. Por cada vector objetivo, la operación mutación produce un vector mutante, como se expresa en la Ecuación 2.14.

$$V_i = x_r 1^t + F(x_r 2^t - x_r 3^t) \quad (2.14)$$

Aquí se tiene que la población original y la de vectores mutados. Con estas poblaciones se generan vectores de prueba con la operación cruce. Se recorren uno a uno los vectores de la Población original y los mutados; para recorrerlos, se toma el primer vector de ambas poblaciones, luego se comparan posición por posición, como se muestra en la Ecuación 2.15:

$$\left. \begin{array}{l} V_{i,k}, \text{if } (Rand_{k,i} \leq CR) \\ X_{i,k}^t, \text{Otherwise} \end{array} \right\} = U \quad (2.15)$$

El vector que tenga mejor fitness entre el vector de prueba U_i y el vector original X_i , este pasa a ser la nueva generación, la cual se expresa en la

Ecuación 2.16:

$$\left. \begin{array}{l} U_{i,k}, \text{ if } (f(U_i) \geq f(X_i)) \\ X_{i,k}^t, \text{ Otherwise} \end{array} \right\} = X_i^{t+1} \quad (2.16)$$

Los operadores mutación, cruce y selección se repiten para originar generaciones tantas veces sea necesario (número de iteraciones) hasta encontrar la solución más óptima. En la Fig. 2.6 se muestra el diagrama de flujo de este modelo.

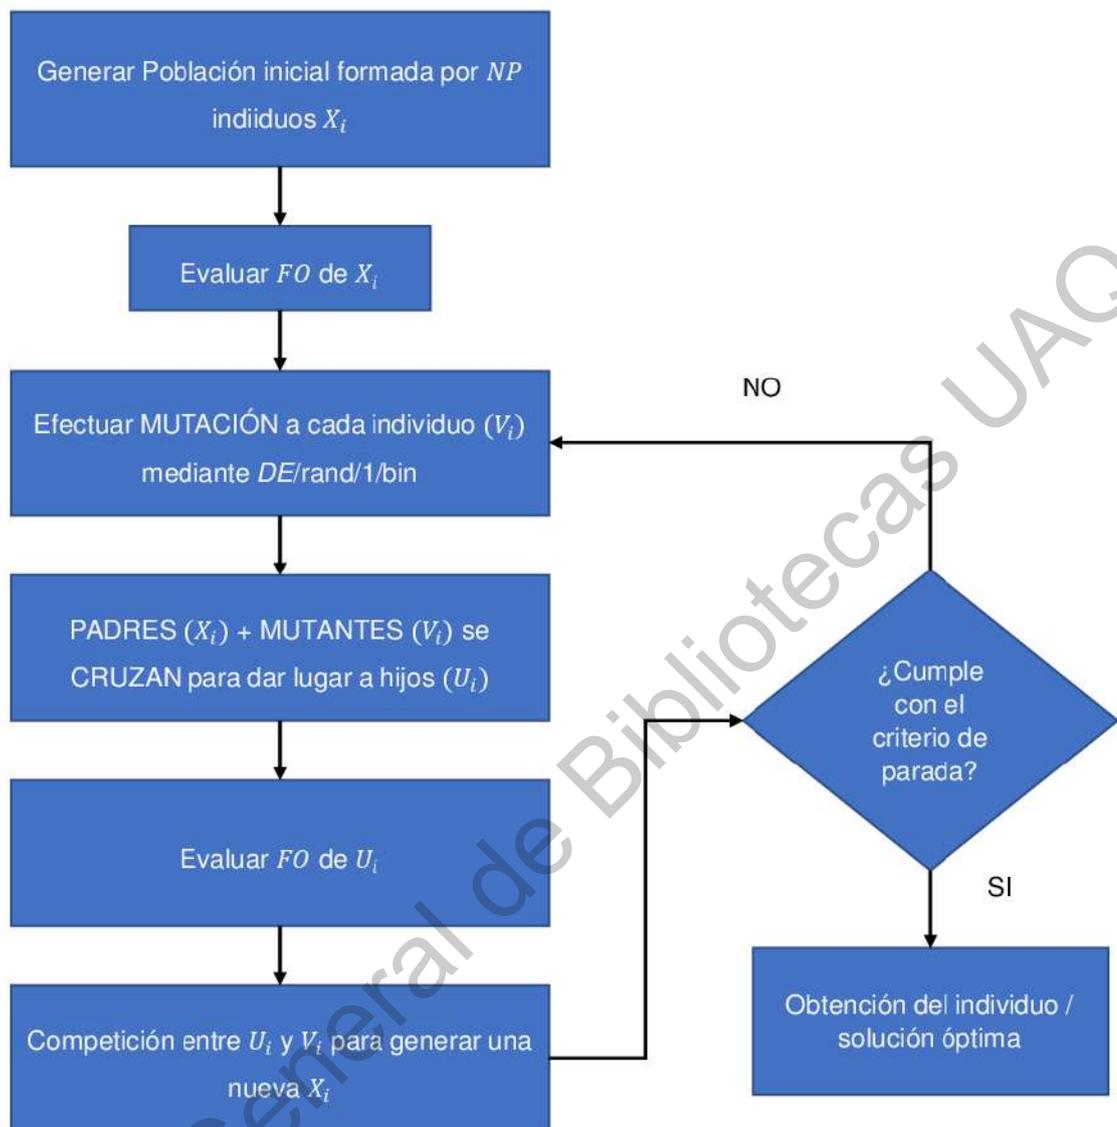


Figura 2.6: Diagrama de flujo del funcionamiento de la evolución diferencial.

2.7. Modelos de evaluación del modelo

Para examinar el desempeño del modelo predictorio de radiación solar con SVM, se valida y compara con modelos deterministas entre los conjuntos de datos de prueba basados en indicadores estadísticos. como el error cuadrático medio (*RMSE*). Habitualmente, las métricas de error habituales para los pronósti-

cos puntuales son la raíz del error cuadrático medio ($RMSE$) y el error de sesgo medio ($BIAS$), definido como las Ecuaciones 2.16 y 2.17, respectivamente (Arbizu-Barrena et al., 2017):

$$RMSE(t) = \sqrt{\frac{1}{N} \sum_{i=1}^N (H_{gprediccion(t),i} - H_{gmedida,i})^2} \quad (2.17)$$

$$BIAS(t) = \frac{1}{N} \sum_{i=1}^N (H_{gprediccion(t),i} - H_{gmedida,i}) \quad (2.18)$$

donde N es el número de datos involucrados en el cálculo, H_g la radiación solar global y t .

HIPÓTESIS

La predicción nowcasting de la radiación solar en zonas urbanas con support vector machine reduce el error de predicción que se genera en sistemas a base de evaluación de variables meteorológicas debido al comportamiento no lineal de dichas variables en las zonas urbanas.

OBJETIVOS

4.1. Objetivo general

Diseñar un modelo de predicción nowcasting de radiación solar global aplicando machine learning mediante el método de máquina de soporte vectorial para reducir el error de 5 % en zona urbana.

4.2. Objetivos específicos

- Recopilar datos de variables meteorológicas mediante base de datos de estaciones meteorológicas y solarimétricas para definir entradas al modelo.
- Desarrollar modelos matemáticos de machine learning por medio de variables meteorológicas para la predicción de la radiación solar global.
- Aplicar y validar los modelos de predicción machine learning para la estimación de la radiación solar global basado en máquinas de soporte vectorial mediante el estudio de función de parámetros.
- Comparar la salida de la machine learning con los datos de las variables de las estaciones meteorológicas de la ciudad de Querétaro a través de modelos estadísticos a corto plazo para la validación de la hipótesis.

METODOLOGÍA

Acorde con las necesidades descritas anteriormente, en la Fig. 5.1 se muestra la metodología propuesta para el siguiente trabajo de investigación. En primer lugar, se deben adquirir los datos de una estación meteorológica pública, los cuales, deberán tener al menos un registro de un año. Luego, se realiza la construcción del modelo con las variables de entrada seleccionadas y se realizan las predicciones en un horizonte temporal nowcast. El ajuste de bondad se lleva a cabo estudiando el error cuadrático medio RMSE para mejorarlo, ejecutando un algoritmo de optimización para la configuración de los parámetros σ y C .



Figura 5.1: Metodología general de la investigación.

Dentro de las herramientas utilizadas en la predicción solar se podrían dividir en aquellas utilizadas para medir datos en tiempo real y aquellas basadas en modelos o métodos en las cuales son introducidos los datos medidos para obte-

ner estimaciones. Dentro del primer grupo, también denominado de “observación terrestre” se encuentran las siguientes herramientas (Ducun, 2014):

- Cámaras de cielo
- Estaciones meteorológicas.
- Imágenes de Satélite.
- Métodos numéricos.Imágenes de Satélite.

5.1. Estudio y selección del área de estudio

El aprovechamiento del recurso solar dependen de su disponibilidad, de las condiciones de iluminación que existen en los espacios, de las obstrucciones que bloquean el paso de la luz, de las edificaciones colindantes y de la topografía del terreno, que puede modificar la cantidad de luz a ciertas horas del día. La ubicación del estado de Querétaro le permite una gran disponibilidad de radiación solar, a diferencia de otras ciudades ubicadas al norte o sur del continente. En promedio, el estado de Querétaro tiene valores de 5 a 6

$$\frac{kWh}{m^2}$$

días durante el verano (del Angel and Gutiérrez, 2019).

Se estableció la capacidad del modelo SVM con un algoritmo genético en la zona metropolitana de la ciudad de Querétaro, México, como caso de estudio. Se seleccionaron principalmente 4 puntos de esta ciudad, debido a que cuentan con una estación meteorológica automática (EMA) dedicada al registro de variables meteorológicas. Una EMA es un sistema equipado con sensores de velo-

cidad del viento, dirección del viento, temperatura del aire, presión atmosférica, humedad del aire y radiación solar global (Nsabagwa et al. 2019). Estas variables permiten estimar el potencial solar de un sitio singular mediante el análisis de promedios mensuales para cada uno. Para estudiar el desempeño de la metodología, se seleccionaron cuatro sitios considerando los datos del sistema AWS disponibles y diferentes climas.

Los sistemas AWS son nombrados oficialmente en México por el Servicio Nacional Meteorológico (SMN) como Huimilpan (AWS1), Presa Jalpan (AWS2), Sierra Gorda-I (AWS3) y Querétaro (AWS4). AWS1 está ubicado en el municipio de Huimilpan en las coordenadas de mercator transversal universal (UTM) 14 Q, 366053 E, 2255193 N y elevación de 2,280 metros sobre el nivel del mar (m.a.s.l.). AWS 2 y 3 están ubicados en el municipio de Jalpan de Serra. El primero en las coordenadas UTM 14 Q, 450998 E, 2345084 N y elevación de 773 msnm; mientras que este último se ubica en 14 Q, 482274 E, 2377396 N y una elevación de 1,111 m.s.n.m. Finalmente, el AWS4 está ubicado en Santiago de Querétaro, ubicado en las coordenadas UTM 14 Q, 358395 E, 2281358 N a una elevación de 1977 m.a.s.l. Los datos de los cuatro sistemas AWS se registraron cada 10 minutos.

El clima en el sitio de Huimilpan se clasifica como templado y cálido según el sistema de clasificación de Köppen y Geiger, con una temperatura promedio de 15.9 ° C y una precipitación anual de 927 mm. Topográficamente, el paisaje se caracteriza por superficies planas o mesetas en su mayoría altas (Campos-Espino 2018). En Presa Jalpan, el clima se clasifica como subtropical húmedo según la misma clasificación; la temperatura media anual es de 23,3°C con una precipitación media anual de 908 mm. En el sitio Sierra Gorda-I, el clima se clasifica como subtropical húmedo y oceánico que alcanza una temperatura media

anual de 15,9 °C con precipitaciones de 927 mm. Topográficamente, Presa Jalpan se ubica en una depresión con montañas a ambos lados. El sitio Sierra Gorda-I está ubicado en un terreno montañoso en una ladera orientada al este hacia el Golfo de México (Carabias-Lillo et al. 1999). Finalmente, la estación de Querétaro se ubica en la cima de un cerro plano. El clima en este sitio se describe como estepa cálida, según la clasificación climática de Köpen-Geigen con una temperatura media anual de 18,7 °C y una precipitación media anual de 574 mm, siendo el verano la temporada con más precipitaciones (Chen y Chen 2013) . Los cuatro sitios en México se consideran un caso de estudio porque tienen una estación meteorológica y diferentes climas según la clasificación climática de Köpen-Geigen. Por lo tanto, es posible evaluar el desempeño del método ejecutándolo en diferentes ubicaciones geográficas con diferentes climas para poder calcular los recursos eólicos y solares disponibles en cualquier parte del mundo con datos meteorológicos para saber si es factible albergar energía eólica, solar o híbrida. plantas de energía. La Fig. 5.2 muestra la ubicación geográfica de las estaciones meteorológicas del estado de Querétaro.



Figura 5.2: Ubicación geográfica de las EMA en el estado de Querétaro.

5.2. Selección de las variables de entrada

Las dificultades y la incertidumbre que implica la medición de la radiación solar global han dado lugar al desarrollo de tantos modelos y algoritmos para su estimación a partir de algunas variables meteorológicas medidas de forma rutinaria que consisten en horas de insolación, temperatura del aire máxima, mínima y media, humedad relativa, factor de nubes, etc (Olatomiwa et al., 2015).

A pesar de dicha indisponibilidad, otros elementos meteorológicos, incluidas las horas de sol, la temperatura ambiente, la humedad relativa, la presión, etc., se miden ampliamente en la mayoría de los sitios debido a sus importantes aplicaciones en diversos campos. Por lo tanto, se han desarrollado varios modelos para estimar la radiación solar global horizontal sobre la base de una serie de parámetros meteorológicos y geográficos comúnmente disponibles que incluyen

la duración de la luz solar, la temperatura ambiente, la humedad relativa, el vapor de agua y las presiones del nivel del mar, la cobertura de nubes, la altitud, la latitud y la longitud y radiación extraterrestre (Mohammadi et al., 2015).

Los modelos empíricos de predicción de radiación solar basados en la temperatura del aire son muy comunes debido a que la temperatura del aire es la variable meteorológica más disponible en todas las estaciones del mundo (Kisi et al., 2019). Aunque los modelos empíricos se han empleado ampliamente para la predicción de la radiación solar, son difíciles de tratar con relaciones no lineales y multidimensionales en entornos ruidosos. Es por esto que se han aplicado varias técnicas de aprendizaje automático para predecir la radiación solar, p. Redes neuronales artificiales (ANN), Máquinas de vectores de soporte (SVM). Entre estos modelos de aprendizaje automático, el modelo SVM se ha empleado recientemente para predecir la radiación solar a partir de la duración de la luz solar o los datos de temperatura del aire debido a sus predicciones más precisas en comparación con los otros modelos usando como base la temperatura del aire (Fan et al., 2018).

La selección de variables juega un papel clave en la determinación del rendimiento de los modelos de predicción. Las características inadecuadas conducirán a una regresión deficiente en un modelo de predicción con cualquier técnica. Se sabe que la radiación solar depende en gran medida de las condiciones meteorológicas. Algunos estudios han demostrado que los modelos predictorios que utilizan determinadas variables meteorológicas adicionales pueden lograr un mejor rendimiento que los que utilizan únicamente datos de radiación solar. La duración del sol, la temperatura del aire, el índice de nubosidad (CI), la transmisividad atmosférica, la duración del día y la hora se pueden utilizar como entradas adicionales para los modelos de predicción de radiación solar (Zeng and

Qiao, 2013).

5.3. Estructura de la Máquina de soportes vectorial

Las SVM presentan varias ventajas sobre otras técnicas no lineales (que incluyen los MLP) (Velásquez et al., 2010):

- a) Su especificación se basa en el principio de minimización del riesgo estructural que equivale a minimizar el límite superior del error de generalización del modelo. Así, la estimación de una SVM busca encontrar tanto la estructura óptima del modelo como los valores óptimos de sus parámetros, permitiendo una mayor capacidad de generalización del modelo. La estimación de los parámetros de otros modelos tradicionales, tales como los MLP, se basa en la aplicación del principio de minimización de riesgo empírico que depende fundamentalmente del ajuste a los datos históricos, tomando la estructura del modelo como un parámetro de entrada.
- b) La estimación de los parámetros de una SVM es equivalente a la solución de un modelo de programación cuadrática con restricciones lineales; ello implica, que la solución óptima es global y única, lo cual representa una clara ventaja sobre modelos como los MLP que se caracterizan por poseer múltiples puntos de mínima local. El problema de programación cuadrática de cuya solución se obtienen los parámetros de las SVM depende de los datos (la serie de tiempo) y de varias constantes que representan los parámetros de la función de núcleo (o kernel) utilizada, y de los parámetros de la función de riesgo .

Existen cuatro núcleos principales que se utilizan predominantemente en SVM, como lineal, polinomial, base radial y sigmoide (Tabla 5.1).

Tabla 5.1: Estado del arte de las técnicas de predicción de radiación solar

Función kernel	Ecuación	Autor
Radial basis function	$K(x_i, x_j) = \exp(-\varsigma \ x_i - x_j\ ^2)$	Shamshirband et al. (2016)
Polinomial	$K(x_i, x_j) = (\varsigma x_i x_j + r)^d$	Yekkehkhany et al. (2014)
Lineal	$K(x_i, x_j) = x_i$	Han et al. (2012)
Sigmoide	$K(x_i, x_j) = \tanh(\varsigma(x_i + x_j) + r)$	Lin and Lin (2003)

En este estudio, se comparan las cuatro funciones de kernel para determinar los parámetros σ y C . La hipótesis de SVM sugirió que el rendimiento de SVM depende del parámetro de holgura ϵ , el factor de costo C y el parámetro del kernel ς mientras se usa la función radial de base (*RBF*) como función del kernel. La C asigna una penalización por el número de vectores que caen entre los dos hiperplanos en la hipótesis. La C sugiere que si los datos son de buena calidad, la distancia entre los dos hiperplanos es más estrecha. Si los datos son ruidosos es preferible tener un valor menor de C que no penalice a los vectores. Por tanto, es importante encontrar el valor C óptimo para el modelado de SVM. En este estudio, estos parámetros (ϵ , C , ς) se optimizaron utilizando el algoritmo genético de evolución diferencial con validación cruzada de cinco veces (CV), variando los valores de ϵ entre 0.002 y 2. La variación los parámetros C entre 0.0001 10. Además, el parámetro de la función del núcleo se ajusta mediante ED, variando los valores de ς entre 0.0001 y 2. GA es una técnica de optimización basada en búsquedas basada en los principios de la genética y la selección natural. GA combina operadores de selección, generación, cruce y mutación para identificar la mejor solución al problema de optimización (Chavero-Navarrete et al., 2019). La

Fig. 5.3 muestra el diagrama de flujo de la arquitectura de la SVM propuesta.

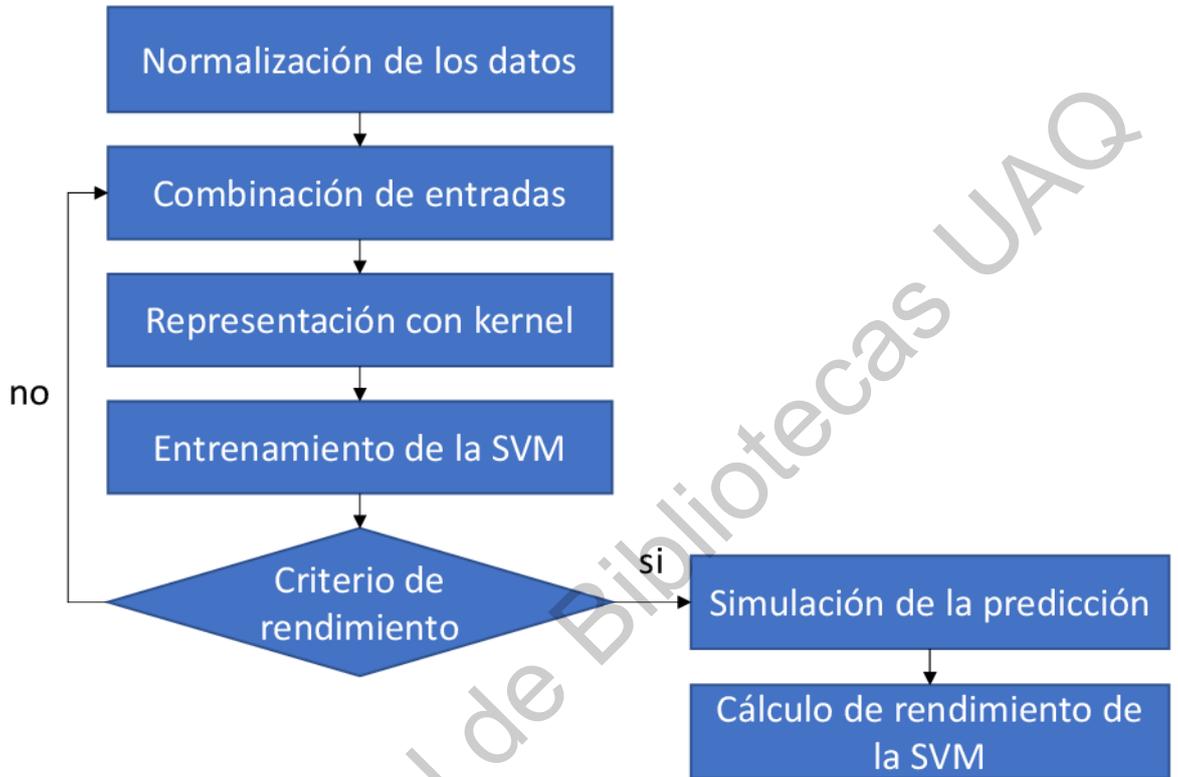


Figura 5.3: Diagrama de flujo de la máquina de soporte vectorial propuesta.

Este modelo propuesto para llevar a cabo la predicción de radiación solar global, es optimizado con el algoritmo de optimización para la búsqueda de los mejores parámetros σ y C , con la finalidad de reducir el error cuadrático medio y obtener un sistema competente. Es por esto, que el diagrama de flujo mencionado en Fig. 5.3, pasa a ser como se muestra en la Fig. 5.4:

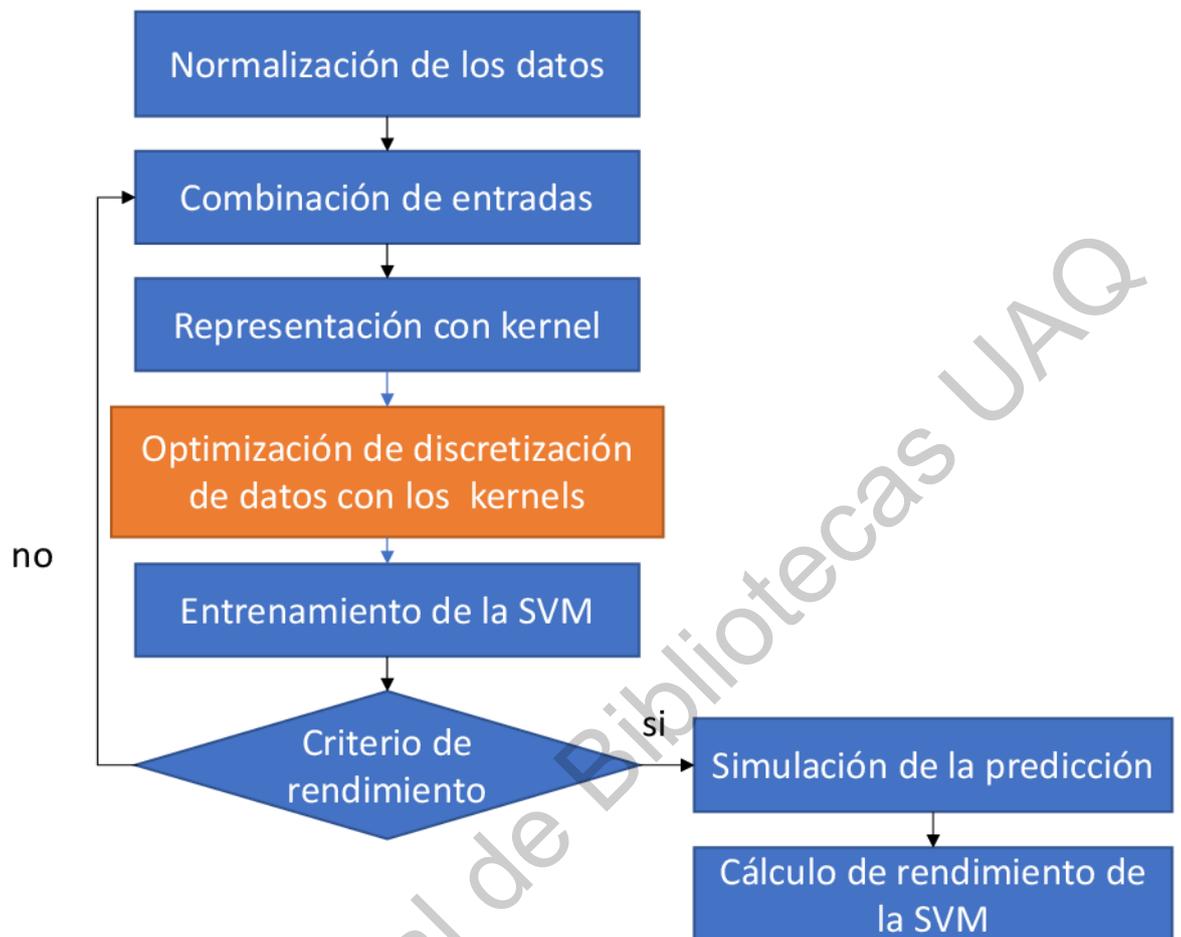


Figura 5.4: Diagrama de flujo SVM + algoritmo genético.

5.4. Selección de parámetros

Dependiendo de los valores de (σ, C, ϵ) , la SVM puede sobreajustarse a la muestra de entrenamiento, tal como ocurre con otros tipos de redes neuronales. Para evadir este problema, los datos para el entrenamiento del modelo son divididos en un conjunto de ajuste con el que se calculan los valores óptimos de los parámetros de (1) dado (σ, C, ϵ) ; y en un conjunto de validación que se usa para determinar si se ha presentado el sobreajuste del modelo. El proceso de optimización de (σ, C, ϵ) se detiene cuando:

1. (σ, C, ϵ) convergió a un punto de mínima.
2. El error cuadrático medio para la muestra de ajuste (MSE) entre las iteraciones k y $k + 1$ (esto es, cuando se ha detectado una dirección en que disminuye el error), se reduce muy lentamente. Dicha velocidad, medida como $(MSE_k - MSE_{k-1})/MSE_k = \epsilon_1$, es inferior a un valor ϵ_1^* predefinido por el experto. Y, cuando la proporción entre los errores de ajuste ($MSET$) y validación ($MSEV$) para la iteración actual, $MSET - MSEV/MSET = \epsilon_2$ es superior a un valor ϵ_2^* predefinido por el experto (Velásquez et al., 2010).

RESULTADOS Y DISCUSIÓN

En este capítulo se describen los resultados obtenidos desde la selección y evaluación del recurso solar en un sitio de estudio, el diseño de los sistemas de predicción y la integración de éstos en zonas urbanas.

6.1. Adquisición de los datos

La estación Solarimétrica ubicada en el Observatorio Meteorológico de la Universidad Autónoma de Querétaro (OMUAQ) (20.626098 latitud norte, -100.359066 longitud oeste) consiste en un seguidor solar Solys2, dos piranómetros Kipp & Zonnen CMP11 con una sensibilidad de 7 a 14 $\mu V/W/m^2$ con un tiempo de respuesta inferior a 5 segundos midiendo la radiación solar difusa y global en plano horizontal; y un pirheliómetro para medir la radiación solar directa. La estación (Fig. 6.1) recopila 100 datos por segundo y almacena el promedio cada minuto con registros del 1 de enero al 31 de diciembre de 2019.

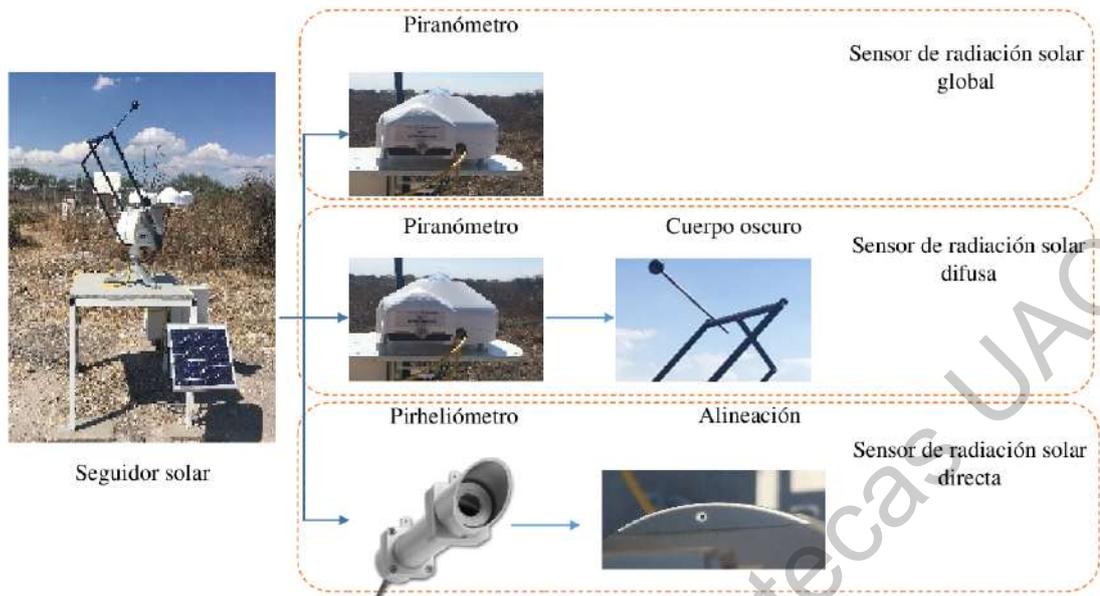


Figura 6.1: Estación solarimétrica para medir componentes de radiación solar.

La estación meteorológica (Fig. 6.2) está equipada con un Barómetro Vaisala PTB110, Termistor C215, Piranómetro Kipp & Zonnen CMP03, anemómetro y pluviómetro Davis Instruments.



Figura 6.2: Estación meteorológica automática Querétaro.

6.2. Estimación del recurso solar

La energía solar capturada en las ubicaciones estudiadas se muestra en la Fig. 6.3. El valor promedio para AWS1, AWS2, AWS3 y AWS4 fue de aproximadamente 511.6, 390.7, 447.8 y 481.6 W/m^2 , respectivamente, con la irradiancia máxima en abril en cuatro ubicaciones, y 2.062 W/m^2 , de radiación promedio total en 1 año. En consecuencia, la instalación de paneles fotovoltaicos para generación solar de energía eléctrica podría ser una opción a gran escala.

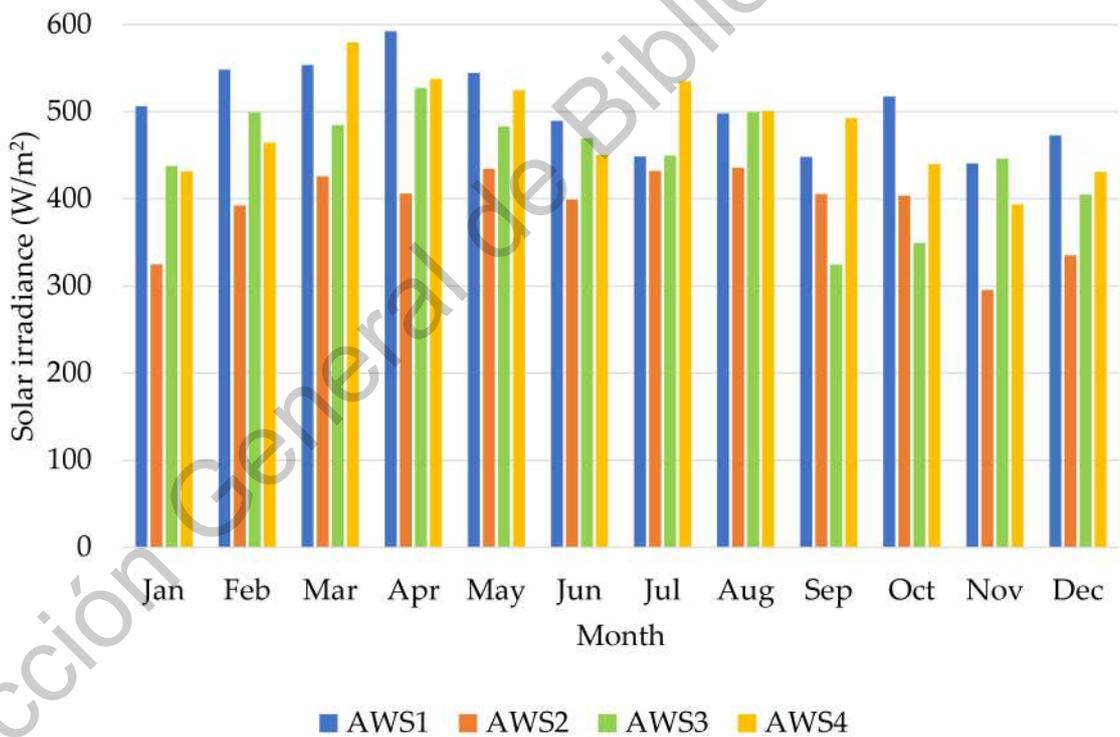


Figura 6.3: Radiación solar promedio en la zona.

El número de horas efectivas por mes SPH en las cuatro ubicaciones durante un año, se muestra en la Fig. 6.4. Las SPH mínimas se encontraron en la temporada de invierno, mientras que los valores máximos se encontraron

durante el verano en las cuatro ubicaciones.

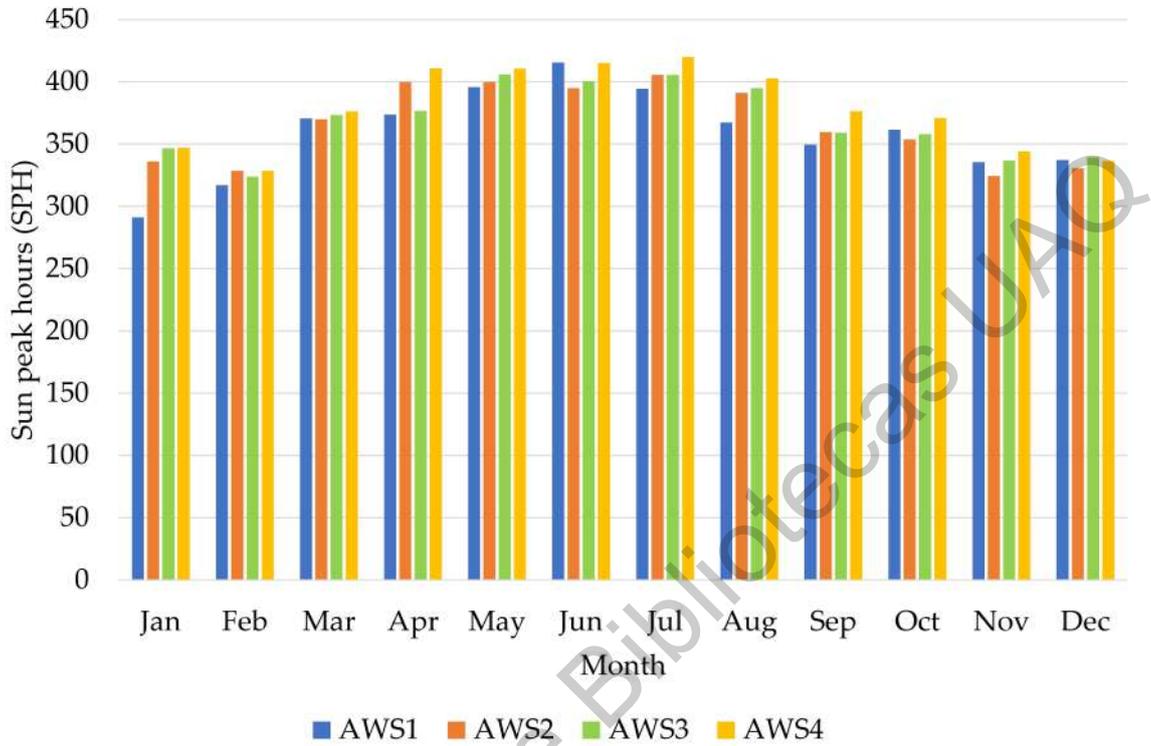


Figura 6.4: Horas solar pico por mes.

La producción promedio diaria de energía solar en las cuatro ubicaciones se muestra en la Fig. 6.5. AWS1 tiene $6.047kWh/m^2$; AWS2 $4,8kWh/m^2$, AWS3 $5,5kWh/m^2$ y AWS4 $6,101kWh/m^2$ Promedio diario de energía solar que se puede producir potencialmente. Sin embargo, el sitio AWS4 mostró que se podría obtener la misma capacidad de generación que el sitio AWS1, con una producción estimada de $6,106 kWh/m^2$.

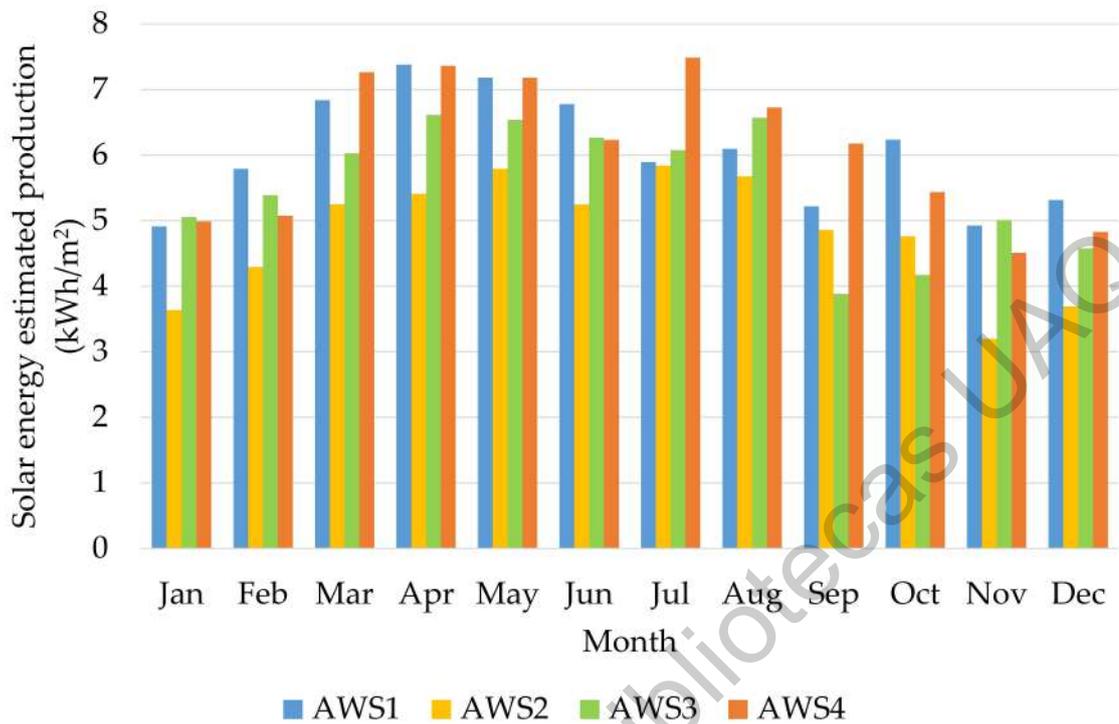


Figura 6.5: Estimación de producción de energía solar.

Esta estimación proporciona el recurso solar disponible para un período de tiempo determinado. Siguiendo este procedimiento, la producción anual de energía solar disponible por m² en los sitios de influencia de los sistemas AWS1, AWS2, AWS3 y AWS4 son 2.1, 1.7, 1.9 y 2.2 MWh/m^2 , respectivamente, sin considerar pérdidas de energía. El bloque de criterios de decisión muestra un gran potencial en AWS1, AWS2 y AWS3 para que la energía eólica sea candidata para albergar sistemas de energía eólica; en generación solar, los cuatro sitios presentan un buen desempeño para albergar sistemas de generación de energía solar excepto en temporada de invierno, considerando los recursos disponibles en el sitio. Así mismo, los resultados muestran que los lugares son aptos para albergar tecnologías de energía solar y, por consecuencia, para integrar modelos de predicción que estimen la radiación solar futura.

6.3. Predicción de radiación solar en sitio

Se utiliza un modelo de clasificación con una ecuación de ajuste polynomial como se muestra en la Fig. 6.6.

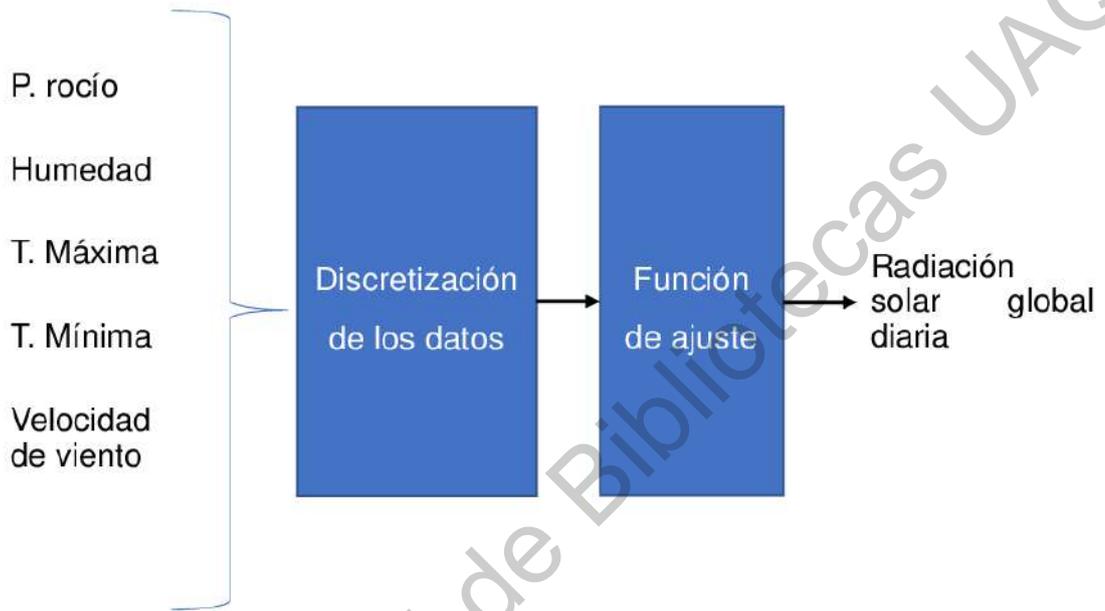


Figura 6.6: Configuración de la SMV para la predicción de radiación solar en sitio.

Para el entrenamiento de la SVM, se procede a seleccionar un horizonte de tiempo intrahorario, el cual, corresponde a una base de datos de siete días soleados con 540 datos obtenidos en intervalos de 10 min de las variables de entrada mostradas en la Figura 6.6, los cuales, serán procesados por medio de la función de base radial de kernel para la construcción de los vectores de soporte en el hiperplano. La Figura 6.7 muestra una relación entre las variables de entrada correspondientes a la base de datos mencionada, en donde se puede apreciar el comportamiento de los datos con la radiación. Se observa que los puntos más negros, son los datos que corresponden a una misma temperatura pero en diferentes días.

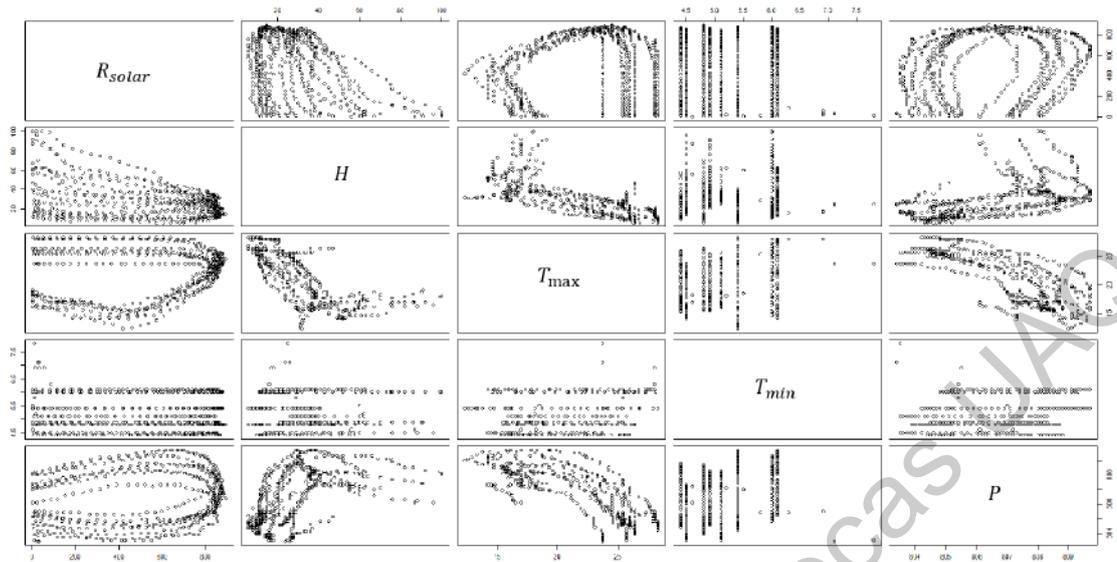


Figura 6.7: Resultado del entrenamiento con SVM.

De acuerdo con el algoritmo de optimización, se logró obtener un ajuste de los parámetros del modelo de SVM con $\gamma = 1$, $\epsilon = 0.2$ y $C = 4$. Para evaluar el rendimiento del modelo SVR, se graficaron las radiaciones solares observadas frente a las previstas. La Figura 6.8 ilustra los resultados con un índice de entrenamiento de correlación R^2 entre los datos observados y predichos en las fases de 0.9341. entrenamiento, por lo que es posible ver que la mayoría de los datos sigue la línea de tendencia de los datos reales.

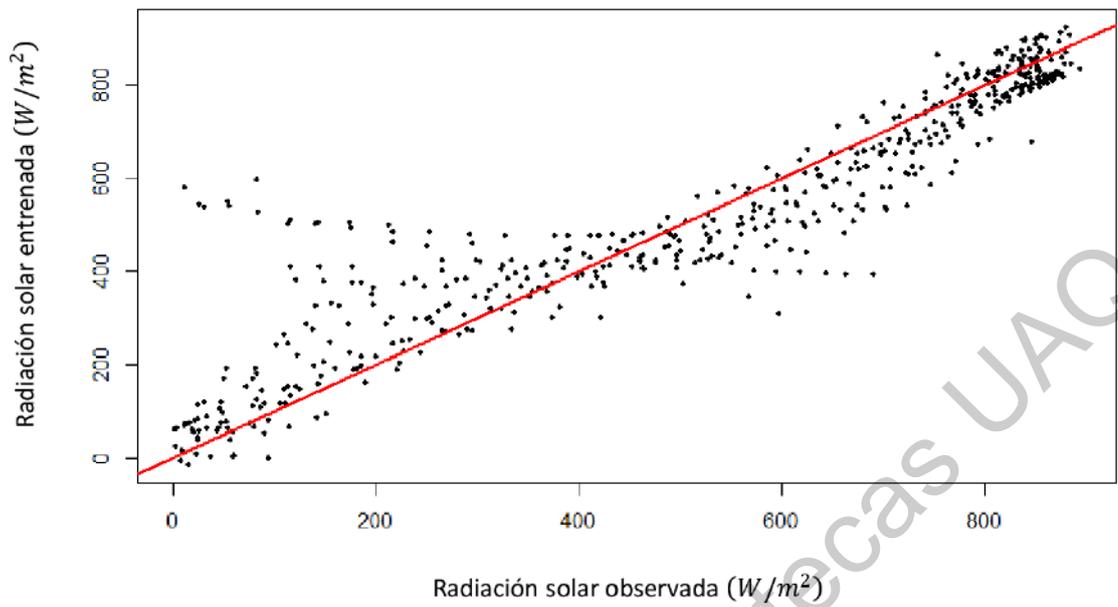


Figura 6.8: Resultado del entrenamiento con SVM.

Así mismo, el entrenamiento final, muestra una trayectoria de la radiación solar estimada contra la real, por lo que es posible visualizar la etapa de entrenamiento en la Figura 6.9.

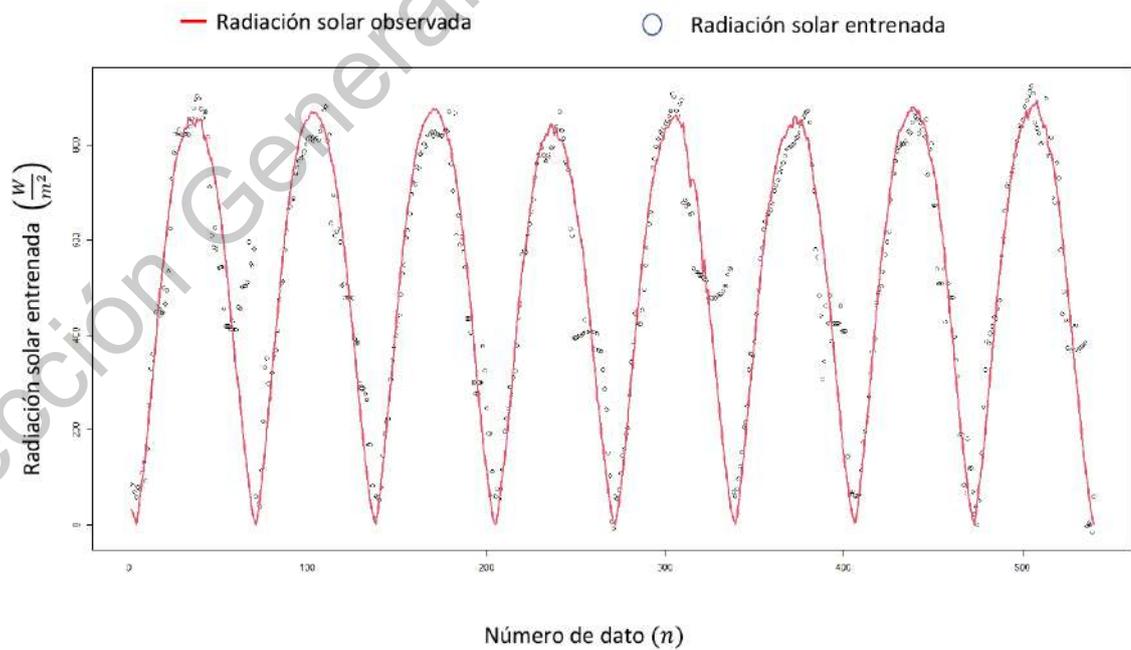


Figura 6.9: Trayectoria de la radiación solar entrenada vista desde la real.

Una vez finalizado el entrenamiento, los datos entrenados en la SVM se puede observar que la SVM interpreta los datos de acuerdo a la función RBF. El entrenamiento se hizo a través del software Rstudio. Para validar el entrenamiento de los datos de entrada al modelo SVM, se realizó la predicción de radiación solar a corto plazo del día siguiente que corresponde a un 13 de febrero. La correlación de la radiación predicha contra los datos observados de ese día son mostrados en la Figura 6.10, la cual muestra un coeficiente de correlación R^2 de 0.9636, lo que equivale a un error de 3.64 %, lo que valida la hipótesis de obtener un modelo de predicción con un error menor al 5%.

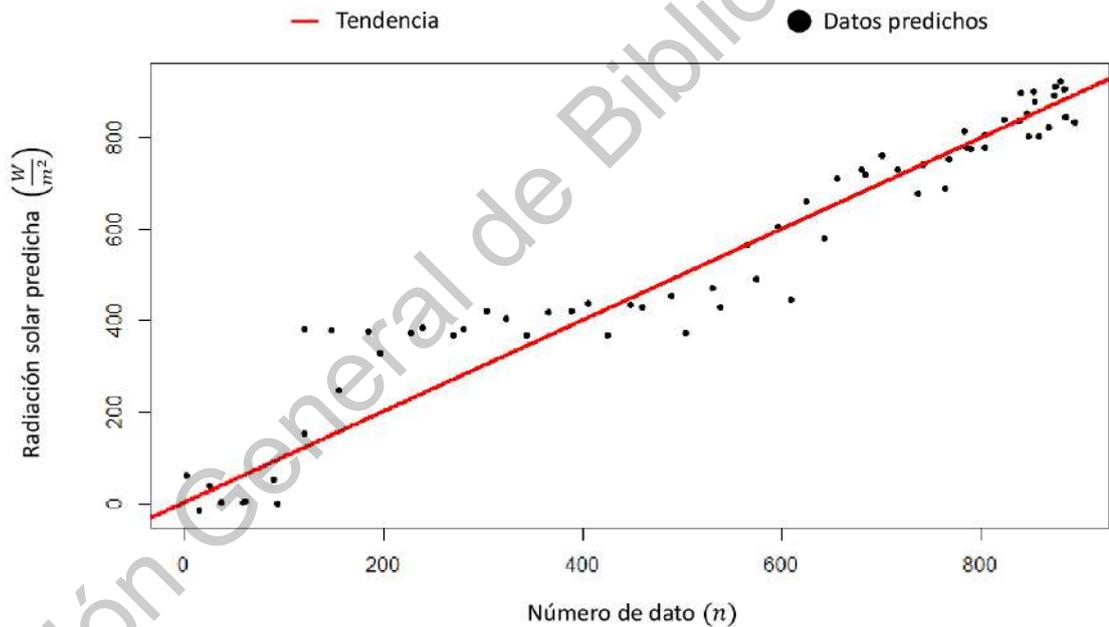


Figura 6.10: Rendimiento de la predicción de radiación solar predicha contra la real.

Esta radiación solar predicha corresponde a un día soleado en una zona urbana. Se puede observar la trayectoria de la campana de la radiación solar predicha en comparación con la real, siendo un resultado prominente en los modelos de predicción, como se observa en la Figura 6.11.

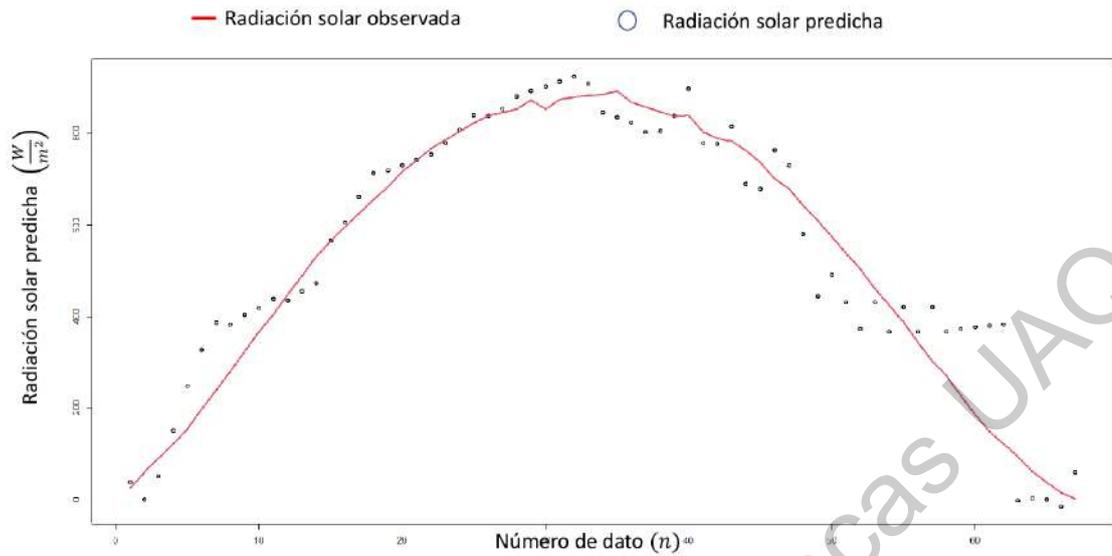


Figura 6.11: Datos de validación de predicción en nowcast.

Estos datos de predicción, muestra una típica relación entre las variables de entrada y la radiación solar de salida del modelo SVM. En la Figura 6.12, se puede observar como las variables siguen el mismo patrón que las variables mostradas en el entrenamiento, interpretando que la SVM resuelve el problema de predicción fácilmente al ser un método de clasificación.

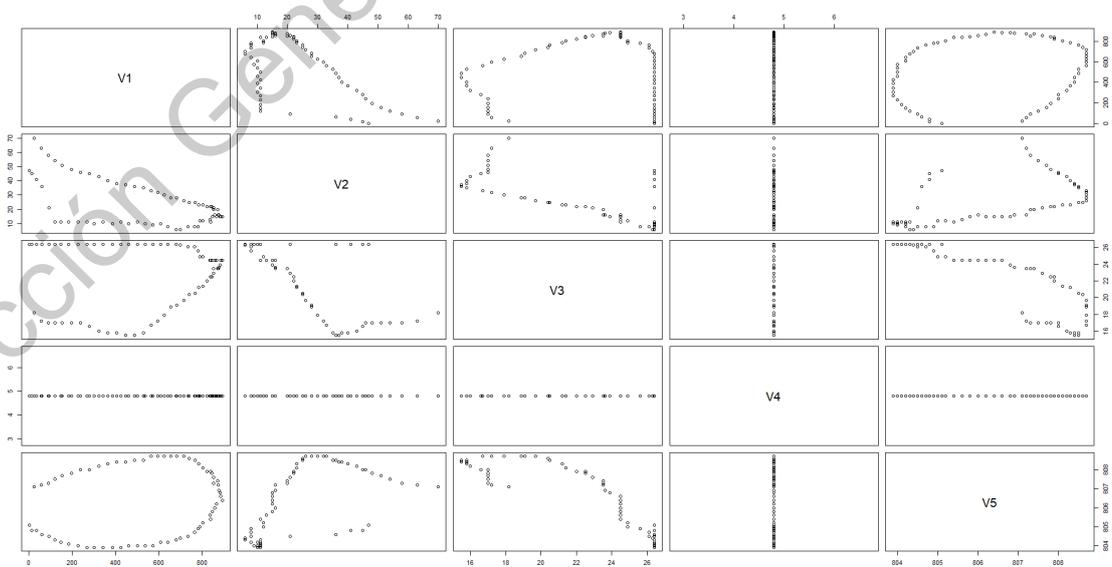


Figura 6.12: Datos de salida de la SVM.

Finalmente, es importante mencionar que el método de búsqueda de los parámetros por medio de la función radial (RBF) presenta un mejor rendimiento en comparación a los modelos de función de kernel polinomial, el cual mostró una correlación de $R^2 = 0.7419$. La Figura 6.12 muestra la diferencia de rendimientos al predecir la radiación solar con los dos diferentes métodos.

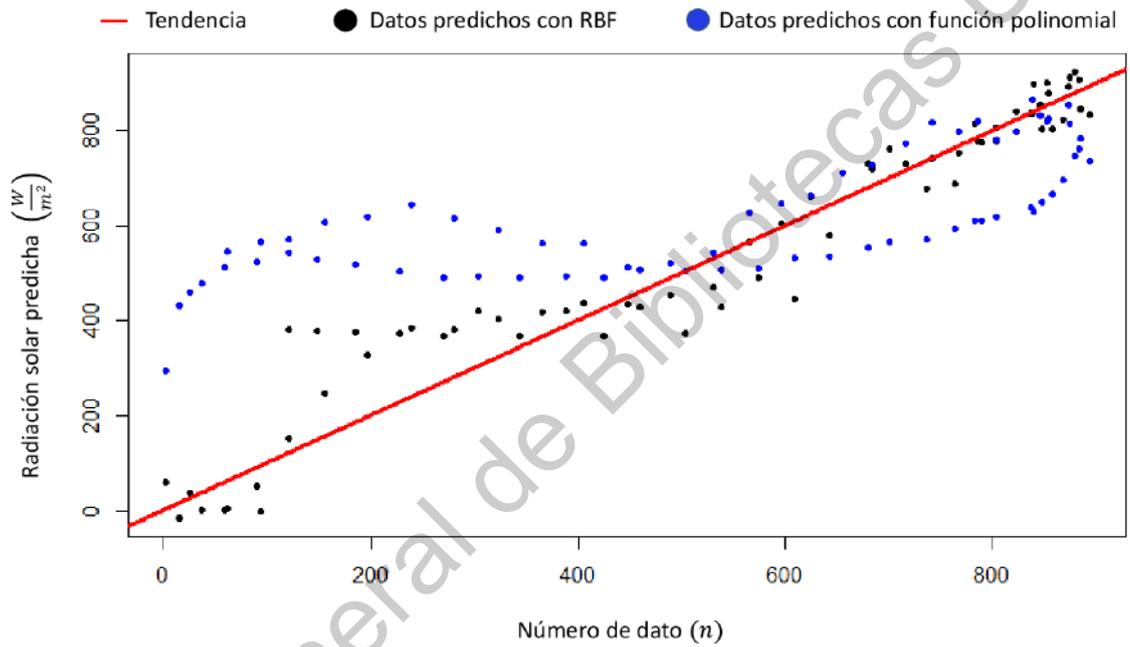


Figura 6.13: Comparativa de los modelos de búsqueda de parámetros del modelo SVM.

CONCLUSIONES

Este trabajo muestra un modelo de predicción de radiación solar global en zonas urbanas por medio de una técnica de Machine Learning de máquinas de soporte vectorial (SVM). La metodología propuesta incluye desde la evaluación del recurso solar de la zona de estudio, el diseño y configuración de la SVM y la búsqueda de los parámetros de las funciones Kernel de esta técnica. Para el recurso solar, se midió la radiación promedio y se determinaron las horas pico de sol (SPH) para conocer la producción teórica de energía solar. Los resultados mostraron una radiación promedio de $6.0 kWh/m^2$ en AWS1, $4.6 kWh/m^2$ en AWS2, $5.3 kWh/m^2$ en AWS3 y $5.7 kWh/m^2$ en el sitio AWS4, con 2.1, 1.7, 1.9 y 2.2 MWh/m^2 de potencial de producción de energía por año respectivamente.

En la parte de predicción, es importante señalar que las variables de entrada al modelo de predicción fueron elegidas de acuerdo al estado del arte: temperatura mínima, temperatura máxima, presión atmosférica y la humedad relativa. Con estas variables. El modelo de predicción por SVM usando un modelo de optimización de búsqueda mejora el rendimiento disminuyendo el error de predicción usando la función de kernel RBF, obteniendo una R^2 de 0.9636 en comparación de un polinomial con una $R^2 = 0.7419$, que, al calcular el error cuadrático medio $RMSE$ puede interpretarse como un error de $40 \frac{W}{m^2}$ con RBF y $132 \frac{W}{m^2}$ para la función polinomial. Lo anterior implica, que un modelo mal optimizado, se traduce en pérdidas o multas para el

planeador de energía eléctrica.

Finalmente, esta metodología alternativa se puede adaptar a cualquier sitio y se puede utilizar como una herramienta que apoyará el conocimiento de los usuarios para planificar, instalar o incluso dimensionar plantas de generación de energía que utilizan fuentes de energía no convencionales disponibles en diferentes sitios. Además, podría ayudar mucho a las estrategias de la sociedad del futuro para enfrentar el desafío en la gestión y el transporte de la energía a través del conocimiento de los sitios potencialmente disponibles, lo que será conveniente contar con esa energía limpia para planificar futuras centrales eléctricas. Así también como en sistemas de generación de energía térmica, en donde se pueda aprovechar la energía solar para generar energía térmica. Estos modelos de predicción ayudan para dimensionar los equipos en este tipo de plantas. Un ejemplo de trabajo a futuro es la integración de un sistema de captación solar en una planta de ciclo Rankine orgánico.

Referencias

- Aler, R., Galván, I. M., Ruiz-Arias, J. A., and Gueymard, C. A. (2017). Improving the separation of direct and diffuse solar radiation components using machine learning by gradient boosting. *Solar Energy*, 150:558–569.
- Alizamir, M., Kim, S., Kisi, O., and Zounemat-Kermani, M. (2020). A comparative study of several machine learning based non-linear regression methods in estimating solar radiation: Case studies of the usa and turkey regions. *Energy*, page 117239.
- Almasoud, A. and Gandayh, H. M. (2015). Future of solar energy in saudi arabia. *Journal of King Saud University-Engineering Sciences*, 27(2):153–157.
- Álvarez-Alvarado, J. M., Ríos-Moreno, J. G., Ventura-Ramos, E. J., Ronquillo-Lomeli, G., and Trejo-Perea, M. (2020). An alternative methodology to evaluate sites using climatology criteria for hosting wind, solar, and hybrid plants. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, pages 1–18.
- Arbizu-Barrena, C., Ruiz-Arias, J. A., Rodríguez-Benítez, F. J., Pozo-Vázquez, D., and Tovar-Pescador, J. (2017). Short-term solar radiation forecasting by advecting and diffusing msg cloud index. *Solar Energy*, 155:1092–1103.
- Bae, K. Y., Jang, H. S., and Sung, D. K. (2016). Hourly solar irradiance prediction based on support vector machine and its error analysis. *IEEE Transactions on Power Systems*, 32(2):935–945.

- Bao, W., Lianju, N., and Yue, K. (2019). Integration of unsupervised and supervised machine learning algorithms for credit risk assessment. *Expert Systems with Applications*, 128:301–315.
- Barboza, F., Kimura, H., and Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83:405–417.
- Belaid, S. and Mellit, A. (2016). Prediction of daily and mean monthly global solar radiation using support vector machine in an arid climate. *Energy Conversion and Management*, 118:105–118.
- Bhola, P. and Bhardwaj, S. (2019). Estimation of solar radiation using support vector regression. *Journal of Information and Optimization Sciences*, 40(2):339–350.
- Cecati, C., Ciancetta, F., and Siano, P. (2010). A multilevel inverter for photovoltaic systems with fuzzy logic control. *IEEE Transactions on Industrial Electronics*, 57(12):4115–4125.
- Chang, T.-P., Liu, F.-J., Ko, H.-H., and Huang, M.-C. (2017). Oscillation characteristic study of wind speed, global solar radiation and air temperature using wavelet analysis. *Applied energy*, 190:650–657.
- Chavero-Navarrete, E., Trejo-Perea, M., Jáuregui-Correa, J. C., Carrillo-Serrano, R. V., and Ríos-Moreno, J. G. (2019). Expert control systems for maximum power point tracking in a wind turbine with pmsg: state of the art. *Applied Sciences*, 9(12):2469.
- Chen, W., Panahi, M., and Pourghasemi, H. R. (2017). Performance evaluation of gis-based new ensemble data mining techniques of adaptive

neuro-fuzzy inference system (anfis) with genetic algorithm (ga), differential evolution (de), and particle swarm optimization (pso) for landslide spatial modelling. *Catena*, 157:310–324.

Cheng, H.-Y. (2016). Hybrid solar irradiance now-casting by fusing kalman filter and regressor. *Renewable Energy*, 91:434–441.

Christodoulou, E., Ma, J., Collins, G. S., Steyerberg, E. W., Verbakel, J. Y., and Van Calster, B. (2019). A systematic review shows no performance benefit of machine learning over logistic regression for clinical prediction models. *Journal of clinical epidemiology*, 110:12–22.

Coady, D., Parry, I., Sears, L., and Shang, B. (2017). How large are global fossil fuel subsidies? *World development*, 91:11–27.

Coello, C. A. C. (1994). Uso de algoritmos genéticos para el diseño óptimo de armaduras. In *Congreso Nacional de Informática "Herramientas Estratégicas para los Mercados Globales"*, pages 290–305.

Cradden, L., Burnett, D., Agarwal, A., and Harrison, G. (2015). Climate change impacts on renewable electricity generation. *Infrastructure Asset Management*, 2(3):131–142.

Cristaldi, L., Leone, G., and Ottoboni, R. (2017). A hybrid approach for solar radiation and photovoltaic power short-term forecast. In *2017 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, pages 1–6. IEEE.

del Angel, L. A. M. and Gutiérrez, A. F. (2019). El derecho al sol: acceso y disponibilidad de la luz natural en querétaro. *Inventio, la génesis de la cultura universitaria en Morelos*, 15(37):1–11.

Deo, R. C., Wen, X., and Qi, F. (2016). A wavelet-coupled support vector machine model for forecasting global incident solar radiation using limited meteorological dataset. *Applied Energy*, 168:568–593.

Eseye, A. T., Zhang, J., and Zheng, D. (2018). Short-term photovoltaic solar power forecasting using a hybrid wavelet-pso-svm model based on scada and meteorological information. *Renewable Energy*, 118:357–367.

Fan, J., Wu, L., Ma, X., Zhou, H., and Zhang, F. (2020). Hybrid support vector machines with heuristic algorithms for prediction of daily diffuse solar radiation in air-polluted regions. *Renewable Energy*, 145:2034–2045.

Fan, J., Wu, L., Zhang, F., Cai, H., Wang, X., Lu, X., and Xiang, Y. (2018). Evaluating the effect of air pollution on global and diffuse solar radiation prediction using support vector machine modeling based on sunshine duration and air temperature. *Renewable and Sustainable Energy Reviews*, 94:732–747.

Fouilloy, A., Voyant, C., Notton, G., Motte, F., Paoli, C., Nivet, M.-L., Guillot, E., and Duchaud, J.-L. (2018). Solar irradiation prediction with machine learning: Forecasting models selection method depending on weather variability. *Energy*, 165:620–629.

Gallucci, D., Romano, F., Cersosimo, A., Cimini, D., Di Paola, F., Gentile, S., Gherardi, E., Larosa, S., Nilo, S. T., Ricciardelli, E., et al. (2018). Nowcasting surface solar irradiance with amesis via motion vector fields of msg-seviri data. *Remote Sensing*, 10(6):845.

Ghimire, S., Deo, R. C., Downs, N. J., and Raj, N. (2018). Self-adaptive differential evolutionary extreme learning machines for long-term solar radiation prediction with remotely-sensed modis satellite and reanalysis at-

atmospheric products in solar-rich cities. *Remote Sensing of Environment*, 212:176–198.

Goldberg, D. E. and Holland, J. H. (1988). Genetic algorithms and machine learning.

Gustavsson, L., Haus, S., Lundblad, M., Lundström, A., Ortiz, C. A., Sathre, R., Le Truong, N., and Wikberg, P.-E. (2017). Climate change effects of forestry and substitution of carbon-intensive materials and fossil fuels. *Renewable and Sustainable Energy Reviews*, 67:612–624.

Gustavsson, L., Haus, S., Ortiz, C. A., Sathre, R., and Le Truong, N. (2015). Climate effects of bioenergy from forest residues in comparison to fossil energy. *Applied Energy*, 138:36–50.

Gutiérrez-Trashorras, A. J., Villicaña-Ortiz, E., Álvarez-Álvarez, E., González-Caballín, J. M., Xiberta-Bernat, J., and Suarez-López, M. J. (2018). Attenuation processes of solar radiation. application to the quantification of direct and diffuse solar irradiances on horizontal surfaces in Mexico by means of an overall atmospheric transmittance. *Renewable and Sustainable Energy Reviews*, 81:93–106.

Han, S., Qubo, C., and Meng, H. (2012). Parameter selection in svm with rbf kernel function. In *World Automation Congress 2012*, pages 1–4. IEEE.

Hossain, M., Madloul, N., Rahim, N., Selvaraj, J., Pandey, A., and Khan, A. F. (2016). Role of smart grid in renewable energy: An overview. *Renewable and Sustainable Energy Reviews*, 60:1168–1184.

Izgi, E., Öztopal, A., Yerli, B., Kaymak, M. K., and Şahin, A. D. (2012). Short-mid-term solar power prediction by using artificial neural networks. *Solar Energy*, 86(2):725–733.

- Jang, H. S., Bae, K. Y., Park, H.-S., and Sung, D. K. (2016). Solar power prediction based on satellite images and support vector machine. *IEEE Transactions on Sustainable Energy*, 7(3):1255–1263.
- Jiang, T., Gradus, J. L., and Rosellini, A. J. (2020). Supervised machine learning: a brief primer. *Behavior Therapy*, 51(5):675–687.
- Jiang, Y. (2009). Daily diffuse solar radiation at beijing. In *2009 World Non-Grid-Connected Wind Power and Energy Conference*, pages 1–4. IEEE.
- Jiménez, L. A. F. (2007). *Modelos avanzados para la predicción a corto plazo de la producción eléctrica en parques eólicos*. PhD thesis, Universidad de La Rioja.
- Karaveli, A. B. and Akinoglu, B. G. (2018). Development of new monthly global and diffuse solar irradiation estimation methodologies and comparisons. *International Journal of Green Energy*, 15(5):333–346.
- Keyhani, A. (2016). *Design of smart power grid renewable energy systems*. John Wiley & Sons.
- Kisi, O., Heddam, S., and Yaseen, Z. M. (2019). The implementation of univariable scheme-based air temperature for solar radiation prediction: New development of dynamic evolving neural-fuzzy inference system model. *Applied Energy*, 241:184–195.
- Lauret, P., Voyant, C., Soubdhan, T., David, M., and Poggi, P. (2015). A benchmarking of machine learning techniques for solar radiation forecasting in an insular context. *Solar Energy*, 112:446–457.
- Li, J., Ward, J. K., Tong, J., Collins, L., and Platt, G. (2016). Machine learning

for solar irradiance forecasting of photovoltaic system. *Renewable energy*, 90:542–553.

Lima, F. J., Martins, F. R., Pereira, E. B., Lorenz, E., and Heinemann, D. (2016). Forecast for surface solar irradiance at the brazilian northeastern region using nwp model and artificial neural networks. *Renewable Energy*, 87:807–818.

Lin, H.-T. and Lin, C.-J. (2003). A study on sigmoid kernels for svm and the training of non-psd kernels by smo-type methods. *submitted to Neural Computation*, 3(1-32):16.

Lorenz, E., Kühnert, J., and Heinemann, D. (2012). Short term forecasting of solar irradiance by combining satellite data and numerical weather predictions. In *Proceedings of the 27th European PV Solar Energy Conference (EU PVSEC), Frankfurt, Germany*, volume 2428, page 44014405.

Lou, S., Li, D. H., Lam, J. C., and Chan, W. W. (2016). Prediction of diffuse solar irradiance using machine learning and multivariable regression. *Applied energy*, 181:367–374.

Mao, X., Yang, H., Huang, S., Liu, Y., and Li, R. (2019). Extractive summarization using supervised and unsupervised learning. *Expert Systems with Applications*, 133:173–181.

Mohammadi, K., Shamsirband, S., Tong, C. W., Arif, M., Petković, D., and Ch, S. (2015). A new hybrid support vector machine–wavelet transform approach for estimation of horizontal global solar radiation. *Energy Conversion and Management*, 92:162–171.

Notton, G., Voyant, C., Fouilloy, A., Duchaud, J. L., and Nivet, M. L. (2019).

- Some applications of ann to solar radiation estimation and forecasting for energy applications. *Applied Sciences*, 9(1):209.
- Olatomiwa, L., Mekhilef, S., Shamshirband, S., Mohammadi, K., Petković, D., and Sudheer, C. (2015). A support vector machine–firefly algorithm-based model for global solar radiation prediction. *Solar Energy*, 115:632–644.
- Paulescu, M. and Paulescu, E. (2019). Short-term forecasting of solar irradiance. *Renewable Energy*, 143:985–994.
- Renno, C., Petito, F., and Gatto, A. (2016). Ann model for predicting the direct normal irradiance and the global radiation for a solar application to a residential building. *Journal of Cleaner Production*, 135:1298–1316.
- Rusen, S. E. and Konuralp, A. (2020). Quality control of diffuse solar radiation component with satellite-based estimation methods. *Renewable Energy*, 145:1772–1779.
- Sanfilippo, A., Martin-Pomares, L., Mohandes, N., Perez-Astudillo, D., and Bachour, D. (2016). An adaptive multi-modeling approach to solar nowcasting. *Solar Energy*, 125:77–85.
- Saravanan, R. and Sujatha, P. (2018). A state of art techniques on machine learning algorithms: a perspective of supervised learning approaches in data classification. In *2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, pages 945–949. IEEE.
- Serrano Jareño, M. A. (2013). *Estudio de irradiancia de bandas del espectro solar. Factores de banda para la caracterización de condiciones atmosféricas en Valencia*. PhD thesis.

- Shalev-Shwartz, S. and Ben-David, S. (2014). *Understanding machine learning: From theory to algorithms*. Cambridge university press.
- Shami, M. and Verhelst, W. (2007). An evaluation of the robustness of existing supervised machine learning approaches to the classification of emotions in speech. *Speech communication*, 49(3):201–212.
- Shamshirband, S., Mohammadi, K., Khorasanizadeh, H., Yee, L., Lee, M., Petković, D., and 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.
- Siddiqui, M. E., Taimoor, A. A., and Almitani, K. H. (2018). Energy and exergy analysis of the s-co₂ brayton cycle coupled with bottoming cycles. *Processes*, 6(9):153.
- Storn, R. and Price, K. (1997). Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11(4):341–359.
- Suganthi, L. and Samuel, A. A. (2012). Energy models for demand forecasting—a review. *Renewable and sustainable energy reviews*, 16(2):1223–1240.
- Sun, X. and Zhang, T. (2017). Solar power prediction in smart grid based on nwp data and an improved boosting method. In *2017 IEEE International Conference on Energy Internet (ICEI)*, pages 89–94. IEEE.
- Tian, Z., Perers, B., Furbo, S., Fan, J., Deng, J., and Dragsted, J. (2018). A comprehensive approach for modelling horizontal diffuse radiation, direct normal irradiance and total tilted solar radiation based on global radiation under danish climate conditions. *Energies*, 11(5):1315.

- Tiwari, S., Sabzehgar, R., and Rasouli, M. (2018). Short term solar irradiance forecast using numerical weather prediction (nwp) with gradient boost regression. In *2018 9th IEEE International Symposium on Power Electronics for Distributed Generation Systems (PEDG)*, pages 1–8. IEEE.
- Velásquez, J. D., Olaya, Y., and Franco, C. J. (2010). Predicción de series temporales usando máquinas de vectores de soporte. *Ingeniare. Revista chilena de ingeniería*, 18(1):64–75.
- Vergara-Barrios, P. P., Rey-López, J. M., Osma-Pinto, G. A., and Ordóñez-Plata, G. (2014). Evaluación del potencial solar y eólico del campus central de la universidad industrial de santander y la ciudad de bucaramanga, colombia. *Revista UIS ingenierías*, 13(2):49–57.
- Voyant, C., Notton, G., Kalogirou, S., Nivet, M.-L., Paoli, C., Motte, F., and Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy*, 105:569–582.
- Xue, X. (2017). Prediction of daily diffuse solar radiation using artificial neural networks. *international journal of hydrogen energy*, 42(47):28214–28221.
- Yao, W., Zhang, C., Hao, H., Wang, X., and Li, X. (2018). A support vector machine approach to estimate global solar radiation with the influence of fog and haze. *Renewable Energy*, 128:155–162.
- Yekkehkhany, B., Safari, A., Homayouni, S., and Hasanlou, M. (2014). A comparison study of different kernel functions for svm-based classification of multi-temporal polarimetry sar data. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40(2):281.

Yesilbudak, M., Colak, M., and Bayindir, R. (2018). What are the current status and future prospects in solar irradiance and solar power forecasting? *International Journal of Renewable Energy Research (IJRER)*, 8(1):635–648.

Zendehboudi, A., Baseer, M., and Saidur, R. (2018). Application of support vector machine models for forecasting solar and wind energy resources: A review. *Journal of cleaner production*, 199:272–285.

Zeng, J. and Qiao, W. (2013). Short-term solar power prediction using a support vector machine. *Renewable Energy*, 52:118–127.

Zhang, J., Verschae, R., Nobuhara, S., and Lalonde, J.-F. (2018). Deep photovoltaic nowcasting. *Solar Energy*, 176:267–276.

Dirección General de Bibliotecas UAO

APÉNDICE A. PRODUCTOS DEL TRABAJO DE INVESTIGACIÓN

8.1. Anexo 1. Artículo en revista indizada

Álvarez-Alvarado, J. M., Ríos-Moreno, G. J., Ventura-Ramos, E., Ronquillo-Lomelí, G., & Trejo-Perea, M. (2019). Experimental Study of a 1-kW Organic Rankine Cycle Using R245fa Working Fluid and a Scroll Expander: A Case Study. *IEEE Access*, 7, 154515-154523.

Experimental Study of a 1-kW Organic Rankine Cycle Using R245fa Working Fluid and a Scroll Expander: A Case Study

J. M. ÁLVAREZ-ALVARADO¹, G. J. RÍOS-MORENO², E. VENTURA-RAMOS, JR.²,
G. RONQUILLO-LOMELI^{2,3}, AND M. TREJO-PÉREA²

¹Dirección de Investigación y Posgrado, Facultad de Ingeniería, Universidad Autónoma de Querétaro, Santiago de Querétaro 76010, México

²Facultad de Ingeniería, Universidad Autónoma de Querétaro, Santiago de Querétaro 76010, México

³Dirección de Energía, Centro de Ingeniería y Desarrollo Industrial, Santiago de Querétaro 76125, México

Corresponding author: G. J. Ríos-Moreno (riosg@uaq.mx)

This work was supported by the SENER-CONACYT sectorial foundation of México under Grant 249606.

ABSTRACT In an organic Rankine cycle (ORC), the study of the cycle efficiencies and the turbine is essential to know the performance in the generation of electrical energy. The proper selection of a working fluid is relevant, because it must be environmentally friendly and compatible with the ORC plant. This article presents an experimental study for the analysis of the cycle and thermal efficiencies on a 1-kW ORC system and the isentropic efficiency of its scroll expander. The test was performed on a 1-kW ORC with scroll expander system with R245fa as the working fluid. Furthermore, it was considered a working temperature below 100 °C, which is used in waste heat recovery systems, to determine the performance of the ORC. The enthalpy is estimated with the *Coolprop* software. For estimating the cycle and thermal efficiency, the net power and the thermal power, which are supplied to evaporate the working fluid, were considered. The isentropic efficiency of the expander was calculated by the scroll mechanical work and the hydraulic work at the scroll expander. The results show that the mean isentropic efficiency of the fluid in the prototype test for ORC in the generation of 1000 W was about 60%, a promising value for the generation of electrical energy using the residual heat from industry.

INDEX TERMS Energy conversion, fluids, power generation, power systems, waste heat.

NOMENCLATURE

η_{cycle}	Cycle efficiency (%)
η_e	Electrical efficiency of the generator (%)
η_{he}	Heat exchanger efficiency (%)
η_{st}	Isentropic efficiency of the scroll expander (%)
η_{th}	Cycle thermal efficiency (%)
CAMD	Computer-aided molecular design
$C_{p,oil}$	Specific heat of the thermal oil ($J/g^\circ C$)
HFC	Hydrofluorocarbon
$h_{p,i}$	Working fluid enthalpies to pump input (kJ/kg)
$h_{p,o}$	Working fluid enthalpy at the high-pressure pump output (kJ/kg)

$h_{s,i}$	Working fluid enthalpy to the expander input (kJ/kg)
$h_{s,o}$	Outlet working fluid enthalpies from the expander (kJ/kg)
I_{ac}	Generated alternating current (A)
m_f	Mass flow of working fluid (kg/s)
m_{oil}	Mass flow of thermal oil (kg/s)
ORC	Organic Rankine cycle
Q_{cond}	Condenser thermal power (W)
Q_{evap}	Thermal power in the evaporator (W)
Q_{he}	Thermal power of the thermal oil (W)
s	Entropy (kJ/kgK)
T	Temperature ($^\circ C$)
$T_{eh,i}$	Input temperature in the heat exchanger ($^\circ C$)
$T_{eh,o}$	Output temperature in the heat exchanger ($^\circ C$)
V_{ac}	120 volts of alternating current

The associate editor coordinating the review of this manuscript and approving it for publication was Ruisheng Diao.

8.2. Anexo 2. Artículo en revista indizada

Álvarez-Alvarado, J. M., Ríos-Moreno, J. G., Ventura-Ramos, E. J., Ronquillo-Lomeli, G., & Trejo-Perea, M. (2020). An alternative methodology to evaluate sites using climatology criteria for hosting wind, solar, and hybrid plants. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 1-18.

Dirección General de Bibliotecas UNO

8.3. Anexo 3. Artículo en revista indizada

Álvarez-Alvarado, J. M., Ríos-Moreno, Obregón-Biosca, S. A., J. G., Ronquillo-Lomeli, G., Ventura-Ramos, E. J. & Trejo-Perea, M. (2020). Hybrid techniques to predict solar radiation using support vector machine and search optimization algorithms: A review. Applied Science, MPDI (enviado).

Dirección General de Bibliotecas UAO

Review

Hybrid techniques to predict solar radiation using support vector machine and search optimization algorithms: A review

José Manuel Álvarez-Alvarado ¹, José Gabriel Ríos-Moreno ^{2,*}, Saul Antonio Obregón-Biosca ², Guillermo Ronquillo-Lomelí ³, Eusebio Jr. Ventura-Ramos ² and Mario Trejo-Perea ²

¹ División de Investigación y Posgrado, Facultad de Ingeniería, Universidad Autónoma de Querétaro, Querétaro 76010, Mexico; jmalvarez@uaq.mx (J.M.A.-A.)

² Facultad de Ingeniería, Universidad Autónoma de Querétaro, Querétaro 76010, Mexico; riosg@uaq.mx (J.G.R.-M.); saul.obregon@uaq.mx (S.A.O.-B.); eventura@uaq.mx (E.J.V.-R.); mtp@uaq.mx (M.T.-P.)

³ Centro de Ingeniería y Desarrollo Industrial, Querétaro 76125, Mexico; gronquillo@cidesi.edu.mx (G.R.-L.)

* Correspondence: riosg@uaq.mx (J.G.R.-M.); Tel.: +52-442-192-1200 (ext. 6064)

Version December 17, 2020 submitted to Appl. Sci.

Abstract: The use of intelligent algorithms for global solar prediction is an ideal tool for research focused on the use of solar energy. The solar radiation prediction supports different applications focused on the generation and transport of energy in places where there are no meteorological stations. Different solar radiation prediction techniques have been applied in different time horizons like neural networks (ANN) or machine learning (ML), the latter being the most important. The support vector machine (SVM) is a classification method of the ML that is used to predict solar radiation. To obtain a better accuracy of prediction data, search optimization algorithms (SOA) like genetic algorithms (GA) and particle swarm optimization algorithm (PSO) were used to optimize the prediction accuracy by searching the model parameters. This article presents a review of different hybrid SVM models with SOA applied to obtain the best parameters to reduce the prediction error of solar radiation using meteorological variables. Research articles from the last 5 years about solar radiation prediction using SVM models and hybrid SMV optimized models with SOA were studied. Results shows that SVM with GA overperformed the classical SVM models using Radial basis kernel function for prediction parameters.

Keywords: solar radiation; support vector machine; heuristic algorithm; renewable energy; solar energy systems

1. Introduction

In recent years, energy generation and transport are very important issues for the social and economic development of any nation that wants to be sustainable. Today, the demand for fossil fuel is 80 % of the total energy consumed globally and more than 95 % is used for the transport sector [1]. The use of these fossil fuels has been one of the main causes of the greenhouse effect that is happening on earth [2–4]. Nowadays, the scientific community has set the task of developing new technologies focused on the generation and use of electricity through the solar resource [5–7].

In this context, power companies must be able to manage energy production to meet consumption at any time [8]. This is why it has focused on generating new techniques to manage energy production, as it is an important factor for a society to thrive economically and without harming the environment by using alternating energies [9]. However, the challenge is that alternating energies (such as solar, wind, to name a few), is that they are not constant and difficult to model. In order to meet the balance

8.4. Anexo 4. Colaboración Artículo en revista indizada

Moreno, J. G. R., Perea, M. T., Lomelí, G. R., Alvarado, J. M. Á., & Ruíz, G. H. (2018, October). Smart window with an embedded control system for thermal comfort in buildings in Mexico. In Proceedings of the Institution of Civil Engineers-Engineering Sustainability (Vol. 172, No. 8, pp. 424-437). Thomas Telford Ltd.

Dirección General de Bibliotecas UNAM

Cite this article

Moreno JG, Perea MT, Lomeli GR, Alvarado JMA and Ruiz GH (2019) Smart window with an embedded control system for thermal comfort in buildings in Mexico. *Proceedings of the Institution of Civil Engineers – Engineering Sustainability* 172(8): 424–437. <https://doi.org/10.1680/jensu.18.00022>

Research Article

Paper 1800022
Received 15/05/2018; Accepted 01/08/2018
Published online 02/10/2018

Keywords: communications & control systems/energy conservation/sustainability

ICE Publishing: All rights reserved

Smart window with an embedded control system for thermal comfort in buildings in Mexico

José Gabriel Ríos Moreno PhD

Professor, Facultad de Ingeniería, Universidad Autónoma de Querétaro, Santiago de Querétaro, Mexico (corresponding author: riosg@uaq.mx) (Orcid:0000-0002-8988-2729)

Mario Trejo Perea PhD

Professor, Facultad de Ingeniería, Universidad Autónoma de Querétaro, Santiago de Querétaro, Mexico (Orcid:0000-0002-7014-3379)

Guillermo Ronquillo Lomeli PhD

Professor, Investigación Aplicada, Centro de Ingeniería y Desarrollo Industrial, Santiago de Querétaro, Mexico (Orcid:0000-0003-2459-1602)

José Manuel Álvarez Alvarado MSc

PhD student, Facultad de Ingeniería, División de Posgrado, Universidad Autónoma de Querétaro, Santiago de Querétaro, Mexico

Gilberto Herrera Ruiz PhD

Professor, Facultad de Ingeniería, Universidad Autónoma de Querétaro, Santiago de Querétaro, Mexico

Globally, buildings are responsible for 40% of the annual energy consumption, most of them using air-conditioning systems that emit gases that contribute to the greenhouse effect. The purpose of this research was to design a proportional, integrating and differentiating (PID) control system for a fluid flowing in a double-skin facade (DSF) in Mexico to generate comfortable temperatures inside a building through heat transfer by circulating the fluid at the desired temperature through the cavity between the panes. Research has shown that the structure of the installed DSF with materials and measurements recommended by the manufacturer was not able to withstand a high-temperature fluid since heat shock occurs in the windows, so a redesign of the structure was made with stronger material and certain considerations. A DSF with a fluid at room temperature served as thermal insulation. The PID control algorithm programmed in the embedded system allowed it to keep the water at the desired temperature and to determine whether it was necessary to circulate fluid at high or low temperatures, consuming about 2000 Wh in the cold season and 3860 Wh in the hot season, which represents savings of 71% energy for the building, resulting in a lower power consumption and a low-emission system.

Notation

A	surface area: m^2
AE_e	energy absorption: J
c	specific heat: $J/^\circ C$
$E(s)$	signal of the error in the frequency domain
$e(t)$	signal of the error in the time domain
g	solar factor: W/m^2
H	reason that heat is transferred: $W = J/s$
I_{RMS}	root mean square current: A
k_d	derivative control
k_i	integrative control
k_p	proportional control
m	body mass: kg
N	half period of a signal
Q	heat that flows in the glass: J
q_e	secondary heat transfer to the outside: J
q_i	secondary heat transfer to the inside: J
RE	energy reflection: J
s	variable in the Laplace domain
TED	direct energy transmission: J
T_i	temperature measured inside the room: $^\circ C$
T_i	integral time
T_o	temperature measured outside the room: $^\circ C$
t	time in the period: s
U	heat transfer coefficient: $W/(m^2 K)$
$U(s)$	signal of the controller in the frequency domain

$u(t)$	signal of the controller in the time domain
V_{RMS}	root mean square voltage: V
W	power consumption calculated: W
α_g	energy absorbed by the glass: W/m^2
ΔT	temperature difference across the surface: K
ρ_e	energy directly reflected by the glass: W/m^2
τ_e	energy transmitted directly through the glazing
ϕ_e	wavelength of the sun's ray (nm)

1. Introduction

One strategy for energy-efficient design in buildings and homes is the implementation of double-skin facades (DSFs) that have improved thermal performance compared with the widely used traditional single-glass facades (Oesterle, 2001; Stec and Paassen, 2005). Globally, buildings are responsible for approximately 40% of the annual energy consumption (Omer, 2008). Most of this energy is used for heating, ventilation and air-conditioning (HVAC). These systems have the disadvantages of producing large quantities of carbon dioxide (CO_2) and nitrogen oxide (NO_x) emissions, consequently releasing 10% of greenhouse gas emissions including indirect emissions from electricity use in HVAC systems (Cannistraro *et al.*, 2016; Pomponi *et al.*, 2016). It is necessary to maintain or improve interior comfort conditions. The American Society of Heating, Refrigeration, and Air-conditioning Engineers (ASHRAE, 2010: p. 4) defines thermal comfort as the 'condition of mind that expresses satisfaction with

8.5. Anexo 5. Modelo de Utilidad

México Julio, 2020

Gaceta de la Propiedad Industrial

SOLICITUDES DE PATENTE, DE REGISTROS DE MODELO DE UTILIDAD Y DE DISEÑOS INDUSTRIALES

Solicitudes de Registro de Modelo de Utilidad

- [22] Fecha de presentación: 23/01/2019
[71] Solicitante(s): UNIVERSIDAD AUTONOMA DE QUERETARO [MX]
[72] Inventor(es): Eusebio Jr. VENTURA RAMOS [MX]; Jesús Amado ZUMAYA HERNÁNDEZ [MX]; José Gabriel RÍOS MORENO [MX]; José Manuel ALVAREZ ALVARADO [MX]; Mario TREJO PEREA [MX]
[74] Agente: ARTURO GARCIA RAMIREZ [MX]; Queretaro, 76010, MX
[51] Clasificación CIP: **F01K 2700** (2006.01)
[52] Clasificación CPC: **F01K 2700** (2013.01)
[54] Título: PLANTA DE PRUEBAS CONFIGURABLE DE CICLO RANKINE ORGÁNICO.
[57] Resumen: La presente invención se refiere a una planta de pruebas configurable para el estudio y la caracterización de sistemas de Ciclo Rankine Orgánico y de fluidos de trabajo, la cual tiene un diseño que le permite trabajar con cuatro ciclos de operación configurables: ciclo simple, ciclo con regeneración, ciclo con precalentamiento y ciclo con regeneración y precalentamiento simultáneo; además, la planta cuenta con un sistema de control que protege los componentes de la planta de operar en condiciones que pudieran dañarlos. Este sistema es alimentado por sensores de presión y de flujo másico y regula el flujo de fluido orgánico que ingresa al expansor. Además, el sistema cuenta con un sistema de monitoreo de la temperatura del fluido orgánico en cada etapa del proceso y una interfaz gráfica que permite observar todas las mediciones realizadas y el desempeño global del sistema.



- [21] Número de solicitud: MX/19/2019/000052
[22] Fecha de presentación: 06/02/2019
[71] Solicitante(s): UNIVERSIDAD AUTONOMA DE QUERETARO [MX]
[72] Inventor(es): Guillermo Iván LÓPEZ DOMÍNGUEZ [MX]; Juvenal RODRIGUEZ RESÉNDIZ [MX]; Tania Elisa MONDRAGON SANCHEZ [MX]
[74] Agente: ARTURO GARCIA RAMIREZ [MX]; Queretaro, 76010, MX
[51] Clasificación CIP: **F21V 2300** (2015.01)
[52] Clasificación CPC: **F21V 23003** (2016.08)
[54] Título: SISTEMA MODULAR DE ILUMINACIÓN.
[57] Resumen: El modelo de utilidad sistema modular de iluminación se describe conforme a las figuras que en seguida se anexan: La figura 1.- es una vista en explosivo y perspectiva del del módulo de mando del sistema de iluminación. La figura 2.- es una vista en explosivo y perspectiva del del módulo secundario del sistema de iluminación. La figura 3.- es una vista en perspectiva de la unión por medio de imanes del sistema modular de iluminación.



- [21] Número de solicitud: MX/19/2019/000228
[22] Fecha de presentación: 07/05/2019
[71] Solicitante(s): HANDI-FOIL CORP. [US]
[72] Inventor(es): David SARNOFF [US]; Norton SARNOFF [US]
[74] Agente: RODOLFO RANGEL MARTINEZ [MX]; CIUDAD DE MEXICO, 05320, MX
[51] Clasificación CIP: **B65D 81/38** (2006.01) **B65D 81/34** (2006.01)
[52] Clasificación CPC: **B65D 81/38** (2017.08) **B65D 81/34** (2013.01)
[54] Título: BANDEJA EN COMBINACIÓN CON UNA BOLSA TÉRMICA
[57] Resumen: Se proporciona en una realización una combinación de una bandeja y una bolsa térmica que se utiliza para mantener las temperaturas frías o calientes de los alimentos colocados en la bandeja.



- [21] Número de solicitud: MX/19/2019/000352
[22] Fecha de presentación: 23/07/2019
[71] Solicitante(s): EQUIPOS HIDROMECAÑICOS MC S.A. DE C.V. [MX]
[72] Inventor(es): Fabián Moisés CASTRO VARGAS [MX]; Moisés CASTRO SALINAS [MX]
[74] Agente: CARITINA BEATRIZ ALVAREZ DE LUCIO [MX]; Ciudad de México, 03200, MX
[51] Clasificación CIP: **B60P 3/02** (2006.01)
[52] Clasificación CPC: **B60P 3/18** (2013.01)
[54] Título: CABINA ELEVADA MÓVIL

- [57] Resumen: La presente invención proporciona una cabina elevada móvil con medios independientes para el ascenso y descenso de operarios que facilitan las operaciones de cambio de turno y, para la desconexión de la cabina para facilitar su traslado aéreo en transportes aéreos convencionales. Asimismo, la presente invención proporciona una cabina elevada móvil adaptable a diferentes usos, con mecanismos que mejoran la estabilidad del equipo para hacer frente a vientos fuertes.



- [21] Número de solicitud: MX/19/2019/000416
[22] Fecha de presentación: 23/08/2019
[71] Solicitante(s): Juan Carlos CRUZ SANCHEZ [MX]
[72] Inventor(es): Juan Carlos CRUZ SANCHEZ [MX]
[74] Agente: JUAN CARLOS CRUZ SANCHEZ [MX]; CIUDAD DE MEXICO, 09670, MX
[51] Clasificación CIP: **E04H 14/00** (2006.01) **E04C 2/62** (2006.01)
[52] Clasificación CPC: **E04H 14/00** (2013.01) **E04C 2/623** (2013.01)
[54] Título: CASA 100% ECOLÓGICA – AUTOSOSTENIBLE

- [57] Resumen: Casa 100% Ecológica y Autosostenible con componentes en ecotecnologías y sustentabilidad contribuye, a base de materiales que están libres de CO2. Se logra mantenerla libre de emisiones de gases de efecto invernadero. Proporcionando energías limpias y renovables para el buen funcionamiento de las casas, a través de los elementos de ecotecnología como lo son: calentador solar, panel solar, muros ecotérmicos y pavimentos ecológicos. Así mismo, con la ayuda de la eco-ingeniería se construyen muros verdes, losas verdes y pozos de absorción, con apoyo de la eco-arquitectura se diseña la funcionalidad y ergonomía a través de rampas para gente con capacidades diferentes, incluyendo áreas verdes con follaje que succionan el CO2 y expulsan oxígeno al ambiente. Contribuyendo a la eco-sustentabilidad de la de la edificación.



- [21] Número de solicitud: MX/19/2019/000438
[22] Fecha de presentación: 02/09/2019
[71] Solicitante(s): Luis Fernando PLASCENCIA ACEVEDO [MX]
[72] Inventor(es): Luis Fernando PLASCENCIA ACEVEDO [MX]
[74] Agente: LUIS FERNANDO ALLENDE VILLARROEL [MX]; CIUDAD DE MEXICO, 11930, MX
[51] Clasificación CIP: **C02F 3/12** (2006.01)
[52] Clasificación CPC: **C02F 3/12** (2013.01)
[54] Título: MODELO DE UTILIDAD. PLANTA DE TRATAMIENTO DE AGUAS RESIDUALES BIO-NAUTILUS

- [57] Resumen: La presente solicitud de MODELO DE UTILIDAD PLANTA DE TRATAMIENTO DE AGUAS RESIDUALES BIO-NAUTILUS, permite llevar a cabo estos procesos en tres etapas, que se controlan de manera automática desde un panel eléctrico, teniendo como principales ventajas en comparación con las plantas de tratamiento de aguas residuales: 1. Procesos con resultados consistentes; 2. Mínima atención por parte del operador; 3. Resiste choques hidráulicos en el influente; 4. Ocupa poco espacio; 5. Los costos de mantenimiento son mínimos; 6. No produce malos olores; 7. Baja producción de lodos; 8. Es un sistema modular, lo que reduce el costo al requerir una expansión futura. Además de tener un Arreglo Típico, que es la distribución de los registros, cárcamos, tanques de almacenamiento así como el arreglo final de la planta se definen de acuerdo al espacio disponible, niveles y características del terreno



- [21] Número de solicitud: MX/19/2019/000444
[22] Fecha de presentación: 03/09/2019
[71] Solicitante(s): Sergio Omar BRACHO MOLINA [MX]
[72] Inventor(es): Sergio Omar BRACHO MOLINA [MX]
[51] Clasificación CIP: **A61H 33/02** (2006.01)
[52] Clasificación CPC: **A61H 33/02** (2013.01)
[54] Título: TINA O ALBERCA CON INYECTORES DE HIDROMASAJE PARA REHABILITACIÓN Y TERAPIA CON BASE EN AGUA ALCALINA ULTRA OZONIFICADA, BIOMAGNETIZADA, IONIZADA, CON CROMOTERAPIA Y MUSICOTERAPIA.

- [57] Resumen: La presente invención se refiere a una tina o alberca de cualquier forma y tamaño provista de inyectores de hidromasaje y de un sistema que permite inyectar ozono grado médico al agua contenida en el reservorio de la tina o alberca, sistema que da lugar a la ultra ozonificación, ionización, alcalinización y biomagnetización del agua, así como la adición de

8.6. Anexo 6. Artículo en revista arbitrada

Alvarado, J. Á., Ríos-Moreno, G. J., Herrera-Ruíz, G., Ventura-Ramos, E., & Trejo-Perea, M. (2018, May). Statistical analysis for the evaluation of solar and wind resources, measured in Querétaro. In 2018 XIV International Engineering Congress (CONIIN) (pp. 1-8). IEEE.

Dirección General de Bibliotecas UAQ

Statistical analysis for the evaluation of solar and wind resources, measured in Querétaro

J.M. Álvarez Alvarado*

División de posgrado, Facultad de Ingeniería
Universidad Autónoma de Querétaro
Querétaro, México

josealvarez1190@gmail.com

*Corresponding Author: josealvarez1190@gmail.com;
riosg@uaq.mx; Tel: +524421921200

G.J. Ríos-Moreno*, G. Herrera-Ruiz, E.Jr. Ventura-Ramos and M. Trejo-Perea

Facultad de Ingeniería
Universidad Autónoma de Querétaro
Querétaro, México

riosg@uaq.mx, gherrera@uaq.mx, eventura@uaq.mx,
mtp@uaq.mx

Abstract—This paper presents a statistical analysis of the wind and solar resource for the urban area of Querétaro to obtain characteristic parameters that allow evaluating the energy resource in the area. To do this, hourly measurements of variables such as solar radiation, ambient temperature, wind speed and direction were considered. A distribution of Weibull is made, which analyzes the wind potential of the wind at the site, explaining the construction of this model. The results obtained are made with the Rstudio program. Finally, a study is shown to obtain the peak sun hours of solar radiation, estimating the solar potential in the area for the winter season.

Keywords— solar radiation, wind potential, wind energy, statistical energy analysis, solar power estimation

I. INTRODUCTION (HEADING 1)

The daily global radiation is important in areas such as: engineering, agriculture, soil physics, agricultural hydrology, crop modeling and estimation of evapo-transpiration, as well as: climate and weather modeling, crop growth monitoring and disease control [1].

According to data from the International Energy Agency (AEI), the main sources of energy worldwide come from oil, coal and natural gas with 34.4%, 26.0% and 20.5% respectively, the above [2]. The burning of hydrocarbons has a negative impact on the environment when emitting greenhouse gases (GHG), such as, among others, CO₂, CH₄ and NO_x. The search for solutions brings with it research on renewable energy sources such as wind, hydro, biomass, geothermal and solar, which are a viable alternative to reduce the amount of GHG emissions [3].

One of the main forms of renewable energy is solar energy, although its intensity varies according to the seasons of the year. Mexico is located in a geographical area whose solar radiation levels are within the stripe with the highest intensity in the world, with average insolation values of $5.7 \frac{kWh}{m^2}$ per day; in Querétaro, a daily average of approximately $5.9 \frac{kWh}{m^2}$ is perceived [4].

The problems generated because of climate change cause the need to increase research in the field of renewable energy. The unconventional technologies have a great economic potential, as well as a low environmental impact. These technologies have not been widely exploited due to the relatively high investment costs, but it must be taken into account that they do not have a fuel consumption to be operated, and this is reflected in the savings of fuel costs [5].

The important parameters for the design, dimensioning and operation of Photovoltaic Systems are the average solar radiation, hourly, daily and monthly [6] and for the wind resource are considered height above sea level, atmospheric pressure, ambient temperature and parameters of wind speed and direction measured in the area [7]. Pyranometers are considered in the measurement for the analysis of the global radiation in different planes as well as the diffuse radiation [8]–[10].

This paper details the statistical analysis of the data acquired from two stations: Meteorological and Solarimetric station, to estimate the energy potential of solar and wind radiation for the city of Querétaro in winter season as a case of study

II. MATERIALS AND METHODS

A. Measurement conditions

The Solarimetric station located in the Observatorio Meteorológico de la Universidad Autónoma de Querétaro (OMUAQ) (20.626098 north latitude, -100.359066 west longitude) consist in a solar tracker Solys2, two pyranometers Kipp&Zonnen CMP11 with a sensitivity from 7 to $14 \mu V / W / m^2$ with a response time of less than 5 seconds measuring diffuse and global solar radiation in horizontal plane; and a pyrhelimeter to measure direct solar radiation. The station (Fig. 1) collects 100 data per second and stores the average every minute with registers from March 5 to March 20, 2018.



The Querétaro State University through the Engineering Faculty grant the present acknowledgment to:

Álvarez Alvarado José Manuel

FOR HIS COLLABORATION:

ORAL PRESENTATION:

Statistical analysis for the evaluation of solar and wind resources, measured in Querétaro

QUERÉTARO, MEX.
MAY 2018

Dr. Manuel Toledano Ayala
PRINCIPAL
ENGINEERING FACULTY

Dr. Gonzalo Macias Bobadilla
GENERAL COORDINATOR CONIIN
ENGINEERING FACULTY

Dirección General de Bibliotecas UAQ

8.7. Anexo 7. Formación de Recurso Humano

Titulación de alumna de Maestría en Ciencias de la Alumna Wendy Alejandra Quintas Frías como sinodal con el tema: Diseño de un modelo basado en algoritmos inteligentes para la obtención del valr del suelo en zonas urbanas.

UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
SECRETARÍA ACADÉMICA

ACTA DE EXAMEN DE GRADO

En la ciudad de Querétaro Qro., siendo las 16:30 horas del día 28 de Febrero de 2019, en las instalaciones de la Facultad de Ingeniería de la Universidad Autónoma de Querétaro, se reunió el jurado designado por la Secretaría Académica en la autorización número 556 de fecha 28 de Febrero de 2019, DR. MARIO TREJO PEREA, PRESIDENTE; MTRA. VERONICA LEYVA PICAZO, SECRETARIO; DR. JOSE GABRIEL RIOS MORENO, VOCAL; MTR. HECTOR ORTIZ MONROY, SINODAL; MTR. JOSE MANUEL ALVAREZ ALVARADO, SINODAL, para efectuar el examen de grado a la

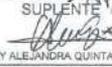
C. WENDY ALEJANDRA QUINTAS FRIAS

Para obtener el Grado de
MAESTRIA EN VALUACION DE BIENES

El acto se realizó de conformidad con el Instructivo de Exámenes Profesionales vigente, expedido por la institución, con base en: La tesis "Diseño de un modelo basado en algoritmos inteligentes para la obtención del valor del suelo en zonas urbanas", realizado por el sustentante, y el resultado fue:

Aprobada por unanimidad de votos

Acto seguido se tomó protesta y para constancia del examen se levanta la presente acta, que firman de conformidad los participantes:

 DR. MARIO TREJO PEREA PRESIDENTE	 MTRA. VERONICA LEYVA PICAZO SECRETARIO
 DR. JOSE GABRIEL RIOS MORENO VOCAL	 MTR. HECTOR ORTIZ MONROY SUPLENTE
 MTR. JOSE MANUEL ALVAREZ ALVARADO SUPLENTE	 WENDY ALEJANDRA QUINTAS FRIAS SUSTENTANTE

Director de Investigación y Posgrado

DRA. MA. GUADALUPE FLAVIA LOARCA PIÑA

Secretario Académico

DR. AURELIO DOMÍNGUEZ GONZÁLEZ

No. de Acta:
2019FIN017354

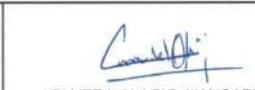
Registro de protocolo y acta de pre-examen de la alumna de Maestría en Ciencias de la alumna Anaisabel Alacio Olvera con el tema "Variables explicativas para la predicción del valor comercial en el sector habitacional mediante redes neuronales artificiales y métodos multicriterio".



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA
DIVISIÓN DE INVESTIGACIÓN Y POSGRADO

REGISTRO DEL PROTOCOLO DE INVESTIGACIÓN
DEL ESTUDIANTE DE POSGRADO

Los 2 Espacios oscuros exclusivos para la Dirección	No. Registro de Proyecto*:	
	Fecha de Registro*:	
	Fecha de inicio de proyecto:	29/07/2019
	Fecha de término de proyecto:	31/03/2021
1. DATOS DEL SOLICITANTE		
No. de expediente:	283980	
Apellido Paterno	Apellido Materno	Nombre(s)
OLVERA	ALACIO	ANAIABEL
Dirección:		
Calle y número	Colonia	C.P.
Fray Buenaventura Tovar #6	El Pueblito	76900
Estado	Teléfono (incluirlada)	Correo Electrónico
22	4422840972	anaisabel.olvera@gmail.com

2. DATOS DEL PROYECTO		
Facultad:	INGENIERÍA	
Programa:	MAESTRIA EN VALUACION DE BIENES	
Tema específico del proyecto:	Variables explicativas para la predicción del valor comercial en el sector habitacional mediante redes neuronales artificiales y métodos multicriterio.	
 RÍOS MORENO JOSE GABRIEL Director de tesis	 LEYVA PICAZO VERONICA Coordinador de programa	 OLVERA ALACIO ANAIABEL Alumno
Dr. Juan Carlos Jáuregui Correa Jefe de División de Investigación y Posgrado de la Fac. de Ing.	Dr. Manuel Toledano Ayala Director de Fac. Ing.	Dra. Ma. Guadalupe Flavia Loarca Piña Directora de Investigación y Posgrado UAQ



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
DIVISIÓN DE ESTUDIOS DE POSGRADO
FACULTAD DE INGENIERÍA

ACTA DE PRE-EXAMEN

Lugar: Querétaro, Qro 16 de diciembre de 2020

Nombre del Alumno y No. De Expediente: Anaisabel Olvera Alacio
Exp. 283980

Programa (nombre completo de la Especialidad, Maestría o Doctorado)

Maestría en Valuación de Bienes de la Facultad de Ingeniería

Tema de Tesis: Variables explicativas para la predicción del valor comercial en el sector habitacional mediante redes neuronales artificiales y métodos multicriterio

Asistencia del Jurado

Nombre completo	Cargo
<u>Dr. José Gabriel Ríos Moreno</u>	<u>Presidente</u>
<u>Dr. Mario Trejo Perea</u>	<u>Secretario</u>
<u>M.C. Verónica Leyva Picazo</u>	<u>Vocal</u>
<u>M.C. José Manuel Álvarez Alvarado</u>	<u>Suplente.</u>

Inasistencias del Jurado

Nombre completo	Cargo
<u>M.en C. Wendy Alejandra Quintas Frías</u>	<u>Suplente.</u>

Registro de protocolo del alumno de Licenciatura Diego Armando Sainz Olvera con el tema: Ahorro de consumo de energía eléctrica por medio de un controlador inteligente para el sector residencial basado en un dispositivo embebido.

Ingeniería en Automatización

 UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA 

Querétaro, Qro., 5 de Noviembre de 2019.

I. DATOS GENERALES

Opción de titulación: Tesis.

Título del trabajo: Ahorro de consumo de energía eléctrica por medio de un controlador inteligente para el sector residencial basado en un dispositivo embebido.

Nombre del alumno: Diego Armando Sainz Olvera

Expediente: 235696

Licenciatura: Ingeniería en Automatización.

Asesor: Dr. José Gabriel Ríos Moreno

Duración: 18 meses.

Número de contacto: 4421689017

Correo electrónico: diegosainz64@gmail.com


Diego Armando Sainz Olvera
Alumno


Dr. José Gabriel Ríos Moreno
Asesor

C.U. 5 de Octubre de 2019

M en C. José Luis Avendaño Juárez
Coordinador de Ingeniería en Automatización
P r e s e n t e:

Por este conducto comunico a usted que he revisado el protocolo de investigación de la Tesis titulada "Ahorro de consumo de energía eléctrica por medio de un controlador inteligente para el sector residencial basado en un dispositivo embebido" que presenta el alumno Diego Armando Sainz Olvera de Ingeniería en Automatización, Línea terminal en Instrumentación y Control, encontrándolo satisfactorio, por lo que otorgo mi

VOTO APROBATORIO

Sin otro particular de momento, quedo de Usted su servidor.

A T E N T A M E N T E



M. en C. José Manuel Álvarez Alvarado

Vocal

Registro de protocolo del alumno de Licenciatura Elias Gabriel Nápoles Ramos con el tema "Diseño de un sistema embebido para alarmas de seguridad vehicular por medio de la tecnología de Sistema de Posicionamiento Global Tracker".

Ingeniería en Automatización



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA



Centro Universitario, Querétaro, Qro., a 12 de Mayo 2020.

I. DATOS GENERALES

Opción de titulación: Tesis.

Título del trabajo: Diseño de un sistema embebido para alarmas de seguridad vehicular por medio de tecnología de Sistema de Posicionamiento Global Tracker

Nombre del alumno: Nápoles Ramos Elías Gabriel.

Expediente: 257538.

Licenciatura: Ingeniería en Automatización, Línea terminal en Instrumentación y Control de Procesos.

Asesor: Dr. José Gabriel Ríos Moreno.

Duración: 12 meses.

Número de contacto: 4424501556.

Correo electrónico: gabriel.napoles@hotmail.com

Nápoles Ramos Elías Gabriel
Alumno

Dr. José Gabriel Ríos Moreno
Asesor



Santiago de Querétaro, Qro. a 21 de mayo
de 2020

**H. Consejo Académico de la FI
Presente.**

Por medio de la presente les envié un cordial saludo y le informo que el **C. Nápoles Ramos Elías Gabriel (257538)** de la carrera de **Ingeniería en Automatización** plan **INA-14** con **línea terminal en Instrumentación y Control de Procesos**, los **votos aprobatorios del protocolo de tesis individual** titulado: **"Diseño de un Sistema Embebido para Alarmas de Seguridad Vehicular por Medio de Tecnología de Sistema de Posicionamiento Global Tracker"**. Por lo anterior **doy mi visto bueno** para la realización del trabajo.

Sin más por el momento quedo de ustedes para cualquier duda o aclaración sobre el particular.

Atentamente,

Ing. José Luis Avendaño Juárez
Coordinador de Ing. en Automatización
Facultad de Ingeniería
Universidad Autónoma de Querétaro
luis.avendano@uaq.mx
442.192.12.00 Ext. 6001

Centro Universitario, a 19 de mayo de 2020

Ing. José Luis Avendaño Juárez
Coordinador de la Licenciatura de Ingeniería en Automatización
Presente.

Por medio de la presente y de acuerdo a su solicitud, me permito informarle que he revisado el **Protocolo de Tesis titulado: "Diseño de un Sistema Embebido para Alarmas de Seguridad Vehicular por medio de Tecnología de Sistema de Posicionamiento Global Tracker"**, que para fines de titulación presenta el alumno: Nápoles Ramos Elías Gabriel (257538), y lo he encontrado:

APROBADO.
APROBADO CON CORRECCIONES (Comentarios anexos)
NO APROBADO (Anexan comentarios).

Comentarios:

El alumno atendió puntualmente cada uno de los comentarios en su protocolo, por lo que doy mi voto aprobatorio.

Sin otro particular, le envío un cordial saludo

Atentamente


M. en C. José Álvarez Alvarado
Docente de la FIN de la UAQ

C.c.p. Archivo

8.8. Anexo 8. Participación y organizador de eventos académicos

Organización del coloquio de Ingeniería 2019 en la Universidad Autónoma de Querétaro.



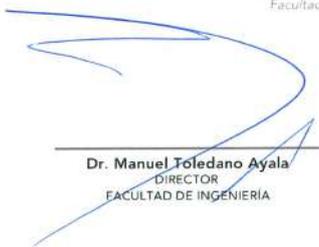
Se otorga el presente
RECONOCIMIENTO a:

JOSÉ MANUEL ÁLVAREZ ALVARADO

Por su valiosa participación en el Comité Organizador del:

**13° Coloquio de Posgrado de
la Facultad de Ingeniería**

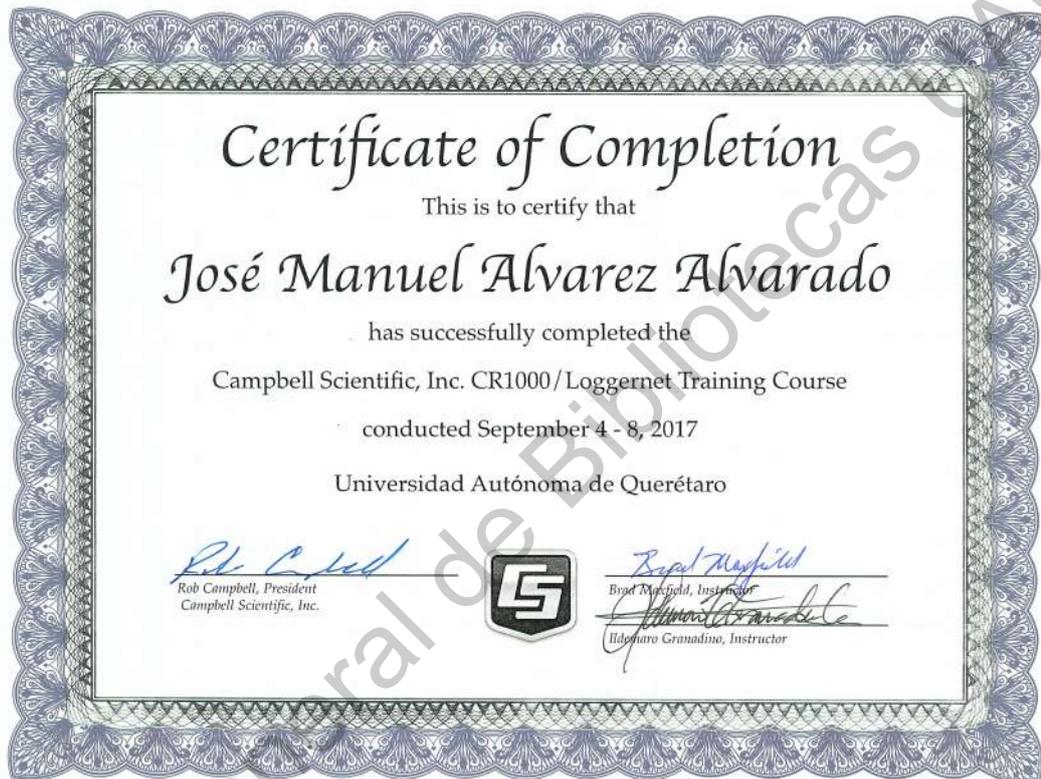
22 de Noviembre de 2019
Facultad de Ingeniería


Dr. Manuel Toledano Ayala
DIRECTOR
FACULTAD DE INGENIERÍA


Dr. Juan Carlos Jáuregui Correa
Jefe de la División de Investigación y Posgrado
FACULTAD DE INGENIERÍA

8.9. Anexo 9. Cursos de formación académica

Se participó en un curso de capacitación con Dataloggers con Campbell Scientific.



8.10. Anexo 10. Seminario Doctoral

Se participó con la ponencia oral: "Estudio de la Radiación solar global: predicción y aprovechamiento para plantas de potencia".



UNIVERSIDAD
AUTÓNOMA
DE QUERÉTARO



FACULTAD
DE INGENIERÍA



DIPFI
POSGRADO
INGENIERÍA

Se otorga el presente
RECONOCIMIENTO a:

M. EN C. JOSÉ MANUEL ÁLVAREZ ALVARADO

Por su participación como PONENTE
en el SEMINARIO DOCTORAL con la conferencia:

**"ESTUDIO DE LA RADIACIÓN SOLAR GLOBAL:
PREDICCIÓN Y APROVECHAMIENTO
PARA PLANTAS DE POTENCIA"**

Campus Querétaro

29 de mayo de 2020
Facultad de Ingeniería

Dr. Manuel Toledano Ayala
DIRECTOR
FACULTAD DE INGENIERÍA