



Estado del arte para métodos de previsión en el pronóstico de la radiación solar en  
celdas fotovoltaicas

Trabajo de grado: Seminario

Andrés Camilo López Meza  
CC 1100966920

Oswaldo Javier Ortiz Pinto  
CC1095944238

**UNIDADES TECNOLÓGICAS DE SANTANDER  
FACULTAD DE CIENCIAS NATURALES E INGENIERÍAS  
TECNOLOGÍA EN IMPLEMENTACIÓN DE SISTEMAS ELECTRÓNICOS  
INDUSTRIALES  
BUCARAMANGA**

**2021**



Estado del arte para métodos de previsión en el pronóstico de la radiación solar en  
celdas fotovoltaicas

Trabajo de grado:

Andrés Camilo López Meza  
CC 1100966920

Oswaldo Javier Ortiz Pinto  
CC1095944238

**Trabajo de Grado para optar al título de**  
Tecnólogo en Implementación de Sistemas Electrónicos Industriales

**DIRECTOR**  
ALFREDO RAFAEL ACEVEDO PICÓN

Grupo de Investigación en Energía - GIE

**UNIDADES TECNOLÓGICAS DE SANTANDER**  
**FACULTAD DE CIENCIAS NATURALES E INGENIERÍAS**  
**TECNOLOGÍA EN IMPLEMENTACIÓN DE SISTEMAS ELECTRÓNICOS**  
**INDUSTRIALES**  
**BUCARAMANGA**  
**2021**

F-DC-125

INFORME FINAL DE TRABAJO DE GRADO EN MODALIDAD DE PROYECTO  
DE INVESTIGACIÓN, DESARROLLO TECNOLÓGICO, MONOGRAFÍA,  
EMPRENDIMIENTO Y SEMINARIO

VERSIÓN: 1.0

### Nota de Aceptación

---

---

---

---

Fra A. González

Firma del Evaluador

Alfredo Acevedo

Firma del Director

## DEDICATORIA

*A DIOS gracias por darnos la sabiduría y inteligencia para concluir con este trabajo.*

*A mi amados padres, Javier y Gloria que siempre estuvieron ayudándome y apoyándome en este proceso.*

*A mi compañero Camilo, que siempre andaba inspiradora con sus ideas de la NASA.*

*Oswaldo Javier Ortiz Pinto*

*A mi familia, amigos y profesores que ayudaron en mi proceso de formación.*

*Andrés Camilo López Meza*

## **Agradecimientos**

### ***A mis profesores***

Sus palabras son muy sabias y su conocimiento es significativo y preciso. Estimados profesores, estoy muy agradecido por los conocimientos brindados.

## TABLA DE CONTENIDO

|                                                                                              |                  |
|----------------------------------------------------------------------------------------------|------------------|
| <b><u>RESUMEN EJECUTIVO.....</u></b>                                                         | <b><u>10</u></b> |
| <b><u>INTRODUCCIÓN.....</u></b>                                                              | <b><u>11</u></b> |
| <b><u>1. DESCRIPCIÓN DEL TRABAJO DE INVESTIGACIÓN .....</u></b>                              | <b><u>13</u></b> |
| 1.1. PLANTEAMIENTO DEL PROBLEMA .....                                                        | 13               |
| 1.2. JUSTIFICACIÓN.....                                                                      | 14               |
| 1.3. OBJETIVOS .....                                                                         | 14               |
| 1.3.1. OBJETIVO GENERAL .....                                                                | 14               |
| 1.3.2. OBJETIVOS ESPECÍFICOS.....                                                            | 14               |
| <b><u>2. MARCO REFERENCIAL .....</u></b>                                                     | <b><u>16</u></b> |
| 2.1. GENERACIÓN FOTOVOLTAICA .....                                                           | 16               |
| 2.2. MATERIALES DE CELDAS FOTOVOLTAICAS .....                                                | 16               |
| 2.3. CARACTERÍSTICAS ELÉCTRICAS DE LAS CELDAS FOTOVOLTAICAS .....                            | 17               |
| 2.4. INTELIGENCIA ARTIFICIAL .....                                                           | 19               |
| 2.5. APRENDIZAJE SUPERVISADO.....                                                            | 20               |
| 2.6. APRENDIZAJE NO SUPERVISADO .....                                                        | 20               |
| 2.7. APRENDIZAJE REFORZADO .....                                                             | 21               |
| 2.8. OTRAS TÉCNICAS DE APRENDIZAJE AUTOMÁTICO .....                                          | 21               |
| <b><u>3. DISEÑO DE LA INVESTIGACION.....</u></b>                                             | <b><u>23</u></b> |
| <b><u>4. DESARROLLO DEL TRABAJO DE GRADO .....</u></b>                                       | <b><u>24</u></b> |
| 4.1. BÚSQUEDA DE INFORMACIÓN .....                                                           | 24               |
| 4.2. ORGANIZACIÓN DE LA INFORMACIÓN.....                                                     | 24               |
| 4.3. ANÁLISIS DE LA INFORMACIÓN.....                                                         | 25               |
| <b><u>5. RESULTADOS .....</u></b>                                                            | <b><u>26</u></b> |
| 5.1. IDENTIFICACIÓN DE DOCUMENTOS.....                                                       | 26               |
| 5.2. TENDENCIAS EN TECNOLOGÍAS SOLARES FOTOVOLTAICAS.....                                    | 28               |
| 5.3. SELECCIÓN DE ENTRADA DEL MODELO DE PREVISIÓN DE ENERGÍA FOTOVOLTAICA .....              | 30               |
| 5.3.1. CORRELACIÓN ENTRE LAS VARIABLES DE ENTRADA Y SALIDA DE POTENCIA<br>FOTOVOLTAICA ..... | 30               |
| 5.3.2. PROCESAMIENTO PREVIO DE DATOS DE ENTRADA DEL MODELO .....                             | 35               |

|                  |                                                                                                    |                  |
|------------------|----------------------------------------------------------------------------------------------------|------------------|
| <b>5.4.</b>      | <b>CLASIFICACIÓN DE LA PREVISIÓN DE GENERACIÓN DE ENERGÍA FOTOVOLTAICA .....</b>                   | <b>35</b>        |
| 5.4.1.           | CLASIFICACIÓN DE LA PREVISIÓN DE ENERGÍA FOTOVOLTAICA BASADA EN EL<br>HORIZONTE DE PREVISIÓN ..... | 36               |
| 5.4.2.           | CLASIFICACIÓN DE LA PREVISIÓN DE ENERGÍA FOTOVOLTAICA BASADA EN DATOS<br>HISTÓRICOS .....          | 37               |
| 5.4.3.           | CLASIFICACIÓN DE LA PREVISIÓN DE ENERGÍA FOTOVOLTAICA BASADA EN MÉTODOS DE<br>PREVISIÓN.....       | 39               |
| <b>5.5.</b>      | <b>ANÁLISIS DE DESEMPEÑO DE DIFERENTES MÉTODOS DE PRONÓSTICO .....</b>                             | <b>45</b>        |
| <b><u>6.</u></b> | <b><u>CONCLUSIONES .....</u></b>                                                                   | <b><u>47</u></b> |
| <b><u>7.</u></b> | <b><u>RECOMENDACIONES .....</u></b>                                                                | <b><u>48</u></b> |
| <b><u>8.</u></b> | <b><u>REFERENCIAS BIBLIOGRÁFICAS .....</u></b>                                                     | <b><u>49</u></b> |

## LISTA DE FIGURAS

|                                                                                                                                                                   |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 1 COMPORTAMIENTO DEL DIODO DE UNIÓN PN DE LA CELDA SOLAR.....                                                                                              | 18 |
| FIGURA 2 COMPORTAMIENTO DEL DIODO DE UNIÓN EN CONDICIONES DE OSCURIDAD PARA CONDICIONES DE POLARIZACIÓN<br>DIRECTA E INVERSA.....                                 | 19 |
| FIGURA 3. ANÁLISIS BIBLIOMÉTRICO DE CITACIONES. ....                                                                                                              | 26 |
| FIGURA 4. ANÁLISIS BIBLIOMÉTRICO DE COOCURRENCIA DE PALABRAS. ....                                                                                                | 27 |
| FIGURA 5. ANÁLISIS BIBLIOMÉTRICO DE COOCURRENCIA DE PALABRAS POR AÑO.....                                                                                         | 28 |
| FIGURA 6. IRRADIANCIA SOLAR Y PATRÓN DE SALIDA DE ENERGÍA FOTOVOLTAICA PARA UN DÍA AL AZAR. ....                                                                  | 31 |
| FIGURA 7. CORRELACIÓN ENTRE LA IRRADIANCIA SOLAR Y LA PRODUCCIÓN DE ENERGÍA FOTOVOLTAICA. ....                                                                    | 32 |
| FIGURA 8. TEMPERATURA ATMOSFÉRICA Y PATRÓN DE PRODUCCIÓN DE ENERGÍA FOTOVOLTAICA PARA UN DÍA EN PARTICULAR...                                                     | 33 |
| FIGURA 9. CORRELACIÓN ENTRE LA TEMPERATURA ATMOSFÉRICA Y LA POTENCIA FOTOVOLTAICA. ....                                                                           | 34 |
| FIGURA 10. TÉCNICAS DE PREVISIÓN BASADAS EN DATOS HISTÓRICOS. ....                                                                                                | 38 |
| FIGURA 11 (A) DIAGRAMA ESQUEMÁTICO DE UNA ESTRUCTURA ANN, QUE CONSTA DE CAPAS DE ENTRADA, OCULTAS Y DE SALIDA.<br>(B) UN MODELO MATEMÁTICO DE UNA CELDA ANN. .... | 42 |



## LISTA DE TABLAS

|                                        |    |
|----------------------------------------|----|
| TABLA 1 MATERIALES FOTOVOLTAICOS ..... | 16 |
|----------------------------------------|----|

## RESUMEN EJECUTIVO

Los sistemas de energía solar y sus tecnologías relacionadas se han convertido en una fuente de energía verde utilizada a nivel mundial. Dados los costos de instalación altos, las bajas tasas de conversión de energía y los problemas de almacenamiento de las baterías, la energía solar aún no es una fuente de energía de aplicación en comparación con las fuentes de energía tradicionales. Sin embargo, el comportamiento de la energía solar es intermitente, lo que presentan una alta inestabilidad de los sistemas fotovoltaicos que suministran energía a la red. Actualmente se usan diferentes tipos de técnicas para poder predecir estos comportamientos, como el uso de técnicas de aprendizaje automático y redes neuronales asociadas a la inteligencia artificial. A pesar de los desafíos, existen muchos estudios innovadores de nuevos materiales y métodos para mejorar la eficiencia de la transformación de la energía solar para mejorar la competitividad de la energía solar en el mercado. En el presente trabajo se elaboró una revisión bibliográfica de diferentes publicaciones encontradas a través de herramientas de búsqueda y revistas indexadas, empleando palabras claves como aprendizaje automático y celdas fotovoltaicas.

**PALABRAS CLAVE.** Aprendizaje automático, inteligencia artificial, sistemas fotovoltaicos, baterías.

## **INTRODUCCIÓN**

La energía es considerada como uno de los desafíos más importante al que se enfrenta la humanidad en la actualidad. La energía solar no solo contribuye a la democratización de la energía, sino que puede mejorar significativamente la vida de las comunidades de todo el mundo. El sol proporciona una gran fuente de energía y juega un papel importante en el complejo de generación de electricidad de muchos países. En particular, la tecnología fotovoltaica (PV) es un método maduro, probado y confiable para convertir la enorme energía del sol en electricidad.

Las plantas de energía solar están ampliamente integradas en la mayoría de los países del mundo. Debido al uso cada vez mayor de sistemas fotovoltaicos, tanto a través de la conexión a la red como de la red autónoma, se esperan cambios drásticos tanto en las fases de diseño como en las de operación del sistema eléctrico. La integración fotovoltaica requiere la capacidad de gestionar la incertidumbre y las fluctuaciones en la producción de energía. En este caso, la previsión fotovoltaica es un aspecto importante para garantizar la planificación y el modelado óptimos del sistema fotovoltaico. Los pronósticos precisos brindan a los operadores de redes y diseñadores de sistemas de energía información útil para diseñar sistemas fotovoltaicos óptimos y administrar el suministro y la demanda de energía. La tecnología fotovoltaica tiene la ventaja de ser móvil y escalable. Por lo tanto, se puede instalar muy rápidamente en varias posiciones. Estas ubicaciones pueden variar desde equipos de tierra tradicionales hasta edificios domésticos y comerciales. Sin embargo, uno de los retos para lograr la difusión de esta tecnología es el precio de la generación de energía fotovoltaica en comparación con las fuentes de energía convencionales. Por lo tanto, las innovaciones en la nueva arquitectura de paneles solares y el desarrollo de materiales son esenciales para el desarrollo de nuevos tipos que pueden reducir el costo de la energía fotovoltaica y generar más energía. Sin embargo, gracias a los avances en la potencia y la velocidad de

la computación, la inteligencia artificial se ha convertido en otro método eficaz para lograr estos objetivos. Nos centraremos en cómo se puede aplicar la inteligencia artificial a la industria fotovoltaica en tres áreas clave: pronóstico y modelado del clima y dimensionamiento del sistema fotovoltaico.

## 1. DESCRIPCIÓN DEL TRABAJO DE INVESTIGACIÓN

### 1.1. PLANTEAMIENTO DEL PROBLEMA

El uso de energía solar a partir de energía fotovoltaica está en auge debido a su bajo costo y alta eficiencia de desempeño debido a su bajo precio de ejercicio, lo que la hace económicamente atractiva. (Castaño-Gómez & García-Rendón, 2020). La mayoría de los paneles comerciales están hechos de silicio y los fabricantes han mejorado sus procesos de fabricación para reducir los costos con el tiempo. (Kaushika et al., 2018b). La estimación de la potencia de salida de un sistema de energía solar es necesaria para que la red funcione correctamente o para una gestión óptima del flujo de energía generado por el sistema solar. (Kaushika et al., 2018a). Antes de predecir el rendimiento del sistema solar, es fundamental centrar la predicción en la radiación solar. (Youssef et al., 2017). Sin embargo, en los últimos años, la implementación de la tecnología de inteligencia artificial ha incrementado enormemente el número de herramientas capaces de predecir diversos tipos de variables relacionadas con los sistemas fotovoltaicos (Mandal et al., 2012). Por lo anterior se quiere dar respuesta a la pregunta: ¿Qué impacto tiene el uso de técnicas de inteligencia artificial en el pronóstico de la irradiancia solar en celdas fotovoltaicas?

## **1.2. JUSTIFICACIÓN**

A medida que las plantas de energía solar se utilicen cada vez más y se conecten tanto a redes como a redes independientes, se producirán cambios drásticos tanto en la planificación como en las etapas operativas de los sistemas de energía. (Soman et al., 2010). La integración fotovoltaica requiere la capacidad de gestionar variaciones y fluctuaciones en la producción de energía. (Precup et al., 2019). En este caso, la previsión fotovoltaica es un aspecto importante para garantizar una planificación y un modelado óptimos de los sistemas fotovoltaicos. (Das et al., 2018). Los pronósticos precisos brindan a los operadores de redes y diseñadores de sistemas eléctricos información útil para diseñar sistemas fotovoltaicos óptimos y administrar la oferta y la demanda. (Hossain et al., 2017; Leva et al., 2017; Youssef et al., 2017). El presente trabajo tiene como objetivo proporcionar una explicación general de los métodos de predicción efectivos utilizando el aprendizaje automático y la inteligencia artificial con el fin de motivar al estudiantado de los programas de la Facultad de Ciencias Naturales e Ingenierías y del grupo de Investigación en Energía – GIE de las UTS para trabajar en temas cercanos a la frontera del conocimiento en cuanto a la fabricación de celdas solares.

## **1.3. OBJETIVOS**

### **1.3.1. OBJETIVO GENERAL**

Elaborar un sondeo descriptivo, sinóptico y analítico del estado del arte del desarrollo e implementación de técnicas de aprendizaje automático e inteligencia artificial sobre la eficiencia de en la predicción de irradiancia solar en celdas fotovoltaicas.

### **1.3.2. OBJETIVOS ESPECÍFICOS**

- Describir las ventajas y desventajas de uso de celdas fotovoltaicas usando técnicas de inteligencia artificial para la predicción de la irradiancia solar usando análisis bibliométricos.
- Identificar avances y limitaciones en el uso de técnicas de aprendizaje automático e inteligencia artificial para la predicción de la irradiancia solar en celdas fotovoltaicas por medio de la construcción de redes bibliométricas.

## 2. MARCO REFERENCIAL

### 2.1. Generación fotovoltaica

Los fotovoltaicos son fuentes de energía modulares que convierten la energía solar en electricidad. Utiliza un material semiconductor para ejercer el efecto fotoeléctrico. Los sistemas fotovoltaicos utilizan módulos solares, cada uno de los cuales consta de una serie de células solares, y generan electricidad a partir de la interacción de esos materiales con la luz solar. Por tanto, la generación de energía fotovoltaica incluye el conocimiento de la ciencia de los materiales y el efecto fotoeléctrico sobre los mismos, incluyendo enlaces atómicos, metales, conductores y aislantes semiconductores, estructuras cristalinas, energías de banda prohibida, uniones PN, interacciones materia-radiación. Contiene conceptos básicos como.(Kaushika et al., 2018a).

### 2.2. Materiales de celdas fotovoltaicas

Los esfuerzos en la tecnología de fabricación de células se resumen en la Tabla 1 en donde se muestran los voltajes en circuito abierto, la corriente en corto circuito y la eficiencia de cada uno de estos (Kaushika et al., 2018a).

Tabla 1 Materiales fotovoltaicos.

| Material                    | Voltaje en circuito<br>abierto (voltio) | Corriente en corto<br>circuito (mA/cm <sup>2</sup> ) | Eficiencia<br>(%) |
|-----------------------------|-----------------------------------------|------------------------------------------------------|-------------------|
| Monocristalino              | 0.6                                     | 35                                                   | 14-15             |
| Policristalino              | 0.6                                     | 35                                                   | 12-13             |
| Arseniuro de galio          | 1.0                                     | 27                                                   | 24                |
| Silicio amorfo en<br>tándem | 1.8                                     | 10                                                   | 25                |



|                                         |     |    |      |
|-----------------------------------------|-----|----|------|
| Silicio amorfo                          | 0.9 | 15 | 9-10 |
| Diselenuro de cobre e<br>indio (CIS)    | 0.4 | 35 | 10   |
| Sulfuro de cadmio,<br>telurio de cadmio | 0.7 | 25 | 10   |


---

Fuente: Kaushika et al., 2018a

### 2.3. Características eléctricas de las celdas fotovoltaicas

Cuando la parte de silicio de tipo n entra en contacto con un semiconductor de tipo p, el límite formado se convierte en una unión PN (Figura 1). Debido a la difusión, los electrones fluyen desde la región de alta concentración (tipo N) a la región de baja concentración (tipo P) y la difusión es la misma para los huecos. Los electrones que salen del plano de tipo n exhiben una carga positiva en el plano de tipo N. Los agujeros que sobresalen de la superficie tipo P están cargados negativamente. Esto da como resultado un desequilibrio de cargas en ambos lados. Se establece un campo eléctrico y se establece el equilibrio contra la tendencia natural de los electrones y los huecos a propagarse.


Figura 1 Comportamiento del diodo de unión PN de la celda solar



Fuente: Kaushika et al., 2018a

La región de transición se llama capa de agotamiento porque los huecos y los electrones se agotan. El comportamiento del diodo de unión PN mencionado anteriormente en condiciones de oscuridad la polarización directa e inversa es bien conocido y se ilustra en la Figura 2.

Figura 2 Comportamiento del diodo de unión en condiciones de oscuridad para condiciones de polarización directa e inversa



Fuente: Kaushika et al., 2018a

Bajo iluminación, la corriente es generada por la célula solar y separada por el paso de un pequeño número de portadores a través de la región de agotamiento, produciendo una gran corriente inversa. La luz generada se superpone a las características voltaje-corriente normalmente rectificadas del diodo. Esto da como resultado una curva  $I/V$  que cubre el cuarto cuadrante con energía eléctrica negativa ( $I/V_V$ ). Esto significa que se puede extraer energía del dispositivo.

## 2.4. Inteligencia artificial

La inteligencia artificial (IA) es un método computacional que tiene como objetivo diseñar sistemas que puedan entender la razón y resolver problemas de una manera similar a la humana (Manaris, 1998). Hoy en día, la tecnología de computación inteligente está reemplazando a la tecnología tradicional o se está integrando en los sistemas existentes. La inteligencia artificial es una amplia gama de temas, que incluyen múltiples temas y subdivisiones. Uno de los temas de especial interés es el campo del aprendizaje automático (ML). En esta área, los algoritmos están diseñados para que se puedan aprender sin ser programados explícitamente (Samuel, 1959). Estos algoritmos pueden utilizar técnicas estadísticas para analizar un conjunto de datos de entrada y hacer predicciones

útiles sobre datos faltantes o futuros. En general, las soluciones de aprendizaje automático se pueden clasificar de acuerdo con la forma en que el algoritmo realiza el aprendizaje. Hay tres ramas principales: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje reforzado (Kaushika et al., 2018a). La siguiente sección proporciona una breve introducción a cada rama del aprendizaje automático y cómo se utilizan otros algoritmos de IA en diferentes aplicaciones fotovoltaicas.

## 2.5. Aprendizaje Supervisado

Este tipo de aprendizaje requiere un supervisor o maestro para ayudar al algoritmo a aprender sus parámetros. Estos algoritmos requieren un conjunto de datos que contenga información sobre los datos de entrada y salida. Durante la fase de entrenamiento, y mientras el algoritmo intenta hacer predicciones sobre el conjunto de datos, el algoritmo modifica el entrenamiento para guiarlo en la dirección correcta y mejorarlo con el tiempo. Además, los métodos de aprendizaje supervisado se pueden dividir en dos categorías principales, según el resultado de la variable que está tratando de predecir. Si la salida es una variable discreta (clase 1, 2 o 3), como predecir si mañana estará soleado, nublado o lluvioso, estos casos se consideran problemas de clasificación. Por otro lado, si la salida requerida es real o continua, como intentar predecir la irradiancia de una ciudad en un momento determinado o determinar el tamaño óptimo de un panel, este caso se convierte en un problema de regresión lineal simple o regresión lineal múltiple. (Franklin, 2005). Algunos ejemplos de algoritmos de aprendizaje supervisado incluyen regresión lineal y logística, vecinos más cercanos, redes neuronales, así como algoritmos más robustos como redes neuronales profundas y sus variaciones.

## 2.6. Aprendizaje no supervisado

El algoritmo de aprendizaje no supervisado no requiere que el supervisor aprenda o prediga el conjunto de datos de entrada. En este caso, estos tipos de algoritmos requieren solo un conjunto de datos de entrada y su objetivo es entrenar

adecuadamente un modelo que represente mejor los datos específicos que se analizarán (Franklin, 2005). Por lo tanto, los métodos de aprendizaje no supervisados incluyen principalmente algoritmos de agrupamiento como K-medias y mapas autoorganizados, ya que estos algoritmos se basan en encontrar patrones en los datos de entrada.

## **2.7. Aprendizaje reforzado**

El aprendizaje por refuerzo, a diferencia de los dos anteriores, se basa en un enfoque de búsqueda de objetivos. Con este enfoque, el programa prueba diferentes acciones para encontrar la mejor para lograr un objetivo en particular. Ejemplos de algoritmos de aprendizaje por refuerzo son los métodos Q Learning y Monte Carlo (Sutton & Barto, 1998).

## **2.8. Otras técnicas de aprendizaje automático**

Otros enfoques de aprendizaje automático incluyen algoritmos genéticos (GA), sistemas expertos (ES), lógica difusa (FL), recocido simulado (SA), colonia de hormigas (ACO) y teoría del enjambre de partículas (PSO). A diferencia de los programas convencionales que resuelven tareas específicas dentro de un rango de condiciones, los sistemas expertos (ES) están diseñados para resolver problemas utilizando el mismo enfoque que los humanos. Por lo tanto, una ES consta de dos partes principales: un motor de inferencia y una base de conocimientos. La base de conocimientos contiene hechos y reglas, mientras que el motor de inferencia tiene como objetivo aplicar estas reglas y hechos para inferir hechos nuevos (Darlington, 2000). Asimismo, se han desarrollado una serie de técnicas de optimización inspiradas naturalmente. Estos incluyen algoritmos genéticos (GA) basados en la genética y principios evolutivos (Thede, 2004). Además, ACO es otro problema de optimización informática inspirado en el comportamiento de las hormigas para encontrar el camino más corto entre el nido y la comida (Dorigo, 1992). Aquí, las hormigas segregan feromonas cuando se mueven al azar hacia la comida. Cuanto

más fuerte sea la feromona, más probable será que la hormiga siga ese camino en particular. Esta técnica se utiliza ahora para optimizar la programación de máquinas y redes de telecomunicaciones. Otras técnicas inspiradas en la naturaleza incluyen optimización del enjambre de partículas (PSO), que está influenciada por el bandadas de pájaros (Youssef et al., 2017). Luego, otro método de optimización de FL que es una rama de la lógica informática diferente de la lógica binaria. (Zadeh, 1996). A diferencia de la lógica booleana, que tiene un valor binario de 1 (verdadero) o 0 (falso), FL permite más posibilidades intermedias en este conjunto. Finalmente, está SA, una técnica de optimización eficiente que se puede utilizar para maximizar o minimizar la función, inspirada en el calentamiento y enfriamiento lento de los sólidos. (Metropolis et al., 1953).

### 3. DISEÑO DE LA INVESTIGACION

La investigación se llevó a cabo de forma descriptiva, en donde se realizó búsqueda de la literatura en todas las áreas afines a la problemática de predicción de irradiancia solar en paneles solares usando técnicas de inteligencia artificial, incluida las tendencias futuras de los autores clave, el número de publicaciones por año, la recopilación de métodos en desarrollo y recomendaciones de investigación, esto se hizo usando programas de construcción y visualización de redes bibliométricas. Asimismo, la investigación cuantitativa permitió cuantificar y explorar en el problema de investigación.

.

#### **4. DESARROLLO DEL TRABAJO DE GRADO**

Con el fin de llevar a cabo los objetivos anteriormente planteados se realizará una investigación descriptiva siguiendo la metodología planteada por Gómez-Luna et al., 2014, donde se presenta una metodología para el estudio, organización y análisis de la literatura en todas las áreas de investigación, facilitando la recopilación de información y tendencias futuras de autores clave, número de publicaciones cada año, investigación de actividades y recomendaciones en áreas clave. De igual manera se recopilará la información de las técnicas y métodos más importantes para el pronóstico de la radiación solar llevando una investigación cuantitativa que permita cuantificar y explorar en el problema de investigación.

##### **4.1. Búsqueda de información**

Una vez definido el alcance y el problema de la investigación se realizó una búsqueda empleando la plataforma Scopus (Burnham, 2006), de tal manera de abarcar el mayor rango de información relacionada con el tema. De igual manera, para hacer uso de esta plataforma se hicieron búsquedas usando palabras claves y abreviaciones de estas, empleando el idioma inglés con el fin de evitar la pérdida de valiosa información. Finalmente se emplearon las palabras “Photovoltaic cells”, “Forecasting” y “artificial intelligence” y se encontraron un total de 171 documentos.

##### **4.2. Organización de la información**

Con el fin de acotar la cantidad de documentos se realizó un agrupamiento empleando los documentos más relevantes y citados. Con lo cual se identificaron los 100 artículos de mayor relevancia. Seguidamente, toda la información recolectada fue descargada y analizada usada el software VOSviewer (Van Eck & Waltman, 2013), con el cual se hizo un análisis bibliométrico más detallado



identificando relaciones entre las citaciones, concurrencia de las palabras y organizaciones o países asociadas a estos documentos. Finalmente se escogieron los 5 documentos más interconectados.

#### **4.3. Análisis de la información**


La información organizada y depurada se analizó teniendo en cuenta los resultados obtenidos en primera instancia, en donde se apreció la relación e interconexión entre las diferentes palabras claves. Seguidamente se analizaron cada uno de los documentos seleccionados identificando la relación e impacto que lo asocian al desarrollo de métodos de pronóstico en celdas fotovoltaicas.

## 5. RESULTADOS

### 5.1. Identificación de documentos

La identificación de los documentos más relevantes se hizo teniendo en cuenta la búsqueda realizada en la base de datos Scopus (Burnham, 2006). En esta se encontraron 171 documentos relacionados con las palabras de interés. Estos documentos se filtraron por número de citas. Posteriormente se agruparon con el software VOSviewer obtenido los resultados de la Figura 3. **Error! No se encuentra el origen de la referencia.**

Figura 3. Análisis bibliométrico de citas.




Fuente: Autor

Seguidamente se realizó un análisis bibliométrico por concurrencia de palabras, obteniendo la relación entre las palabras más relevantes entre todos los documentos (Figura 4). Este análisis permitió observar la conexión que existe entre diferentes palabras que están asociadas a los temas de interés y esto a su vez

permitió consolidar la búsqueda de información y temas relevantes para poder abarcar la búsqueda de información.

Figura 4. Análisis bibliométrico de coocurrencia de palabras.




Fuente: Autor.

Teniendo en cuenta lo anterior las palabras más relevantes y con mayor número de conexiones fueron las siguientes:

- Artificial Intelligence
- Forecasting
- Solar power generation
- Neural networks
- Learning systems
- Machine Learning
- Prediction

De igual manera en la Figura 5 se presenta el mismo análisis, pero en este caso resaltando las palabras clave por fecha de publicación. Este tipo de gráfica permitió observar la evolución de los diferentes temas a lo largo del tiempo y comprender el desarrollo actual de los temas seleccionados.

Figura 5. Análisis bibliométrico de coocurrencia de palabras por año



Fuente: Autor

Finalmente, los resultados mostrados anteriormente permitieron filtrar la información y hacer un análisis inicial de los documentos más relevantes y de mayor importancia asociados a las investigaciones de celdas fotovoltaicas enfocadas a la previsión de diferentes factores usando técnicas de inteligencia artificial

## 5.2. Tendencias en tecnologías solares fotovoltaicas

En los últimos años la demanda global de herramientas fotovoltaicas ha ido en aumento, en 2018 se presentó un aumento de 38,4 GW (frente a 30 GW en 2017)

de nueva capacidad en todo el mundo y 11 GW instalados solo en Europa. El hecho más importante de 2018 fue el rápido desarrollo de la energía fotovoltaica en Asia, tanto en términos de despliegue fotovoltaico como de fabricación de tecnologías fotovoltaicas. En 2003 la potencia era de solamente de 3,7 GW y progresivamente llegó a los 139 GW en 2018. Los principales países en desarrollo de implementación y desarrollo de celdas fotovoltaicas son Alemania, China, Italia, Japón, Estados Unidos, España, Francia, Reino Unido, Australia y Bélgica (Hales, 2020). En Colombia, la generación de energía solar fotovoltaica (FV), es prácticamente nula siendo esta un gran potencial debido a su localización (Castaño-Gómez & García-Rendón, 2020).

Las celdas solares fotovoltaicas se pueden fabricar para diferentes aplicaciones. A medida que el precio de los paneles fotovoltaicos disminuya con la tecnología y las economías de escala, la capacidad instalada de los paneles fotovoltaicos aumentará en la red de transmisión y distribución. La capacidad fotovoltaica mundial alcanzó los 398 GW en 2017, produciendo más de 460 TW de electricidad, de los cuales representan aproximadamente el 2% de la generación eléctrica mundial (IEA, 2018). En Estados Unidos, se instalaron 1,7 GW de capacidad fotovoltaica en el tercer trimestre de 2018, lo que eleva la capacidad instalada a 60 GW. Se espera que la capacidad solar instalada total se duplique en los próximos 5 años. Para 2023, se estima que se instalarán más de 14 GW de capacidad fotovoltaica por año (SEIA, 2018). Se han abordado varios desafíos en el sector energético mejorando la penetración de la tecnología fotovoltaica y contribuyendo en temas como: emisiones de gases de efecto invernadero por la combustión de combustibles fósiles, altos costos de energía, falta de suministro eléctrico en áreas remotas y no desarrolladas, alta transmisión y pérdidas de red en áreas urbanas. La comercialización y el desarrollo son algunos de los retos que puede afrontar la generación fotovoltaica en la actualidad.

### **5.3. Selección de entrada del modelo de previsión de energía fotovoltaica**


La energía solar es una de las energías renovables más comunes y proviene del sol en forma de radiación solar. La mayoría de las celdas solares están hechas de semiconductores que convierten la radiación solar en electricidad a través del efecto fotovoltaico. La generación de energía solar es proporcional a la cantidad de radiación solar. Además, otros parámetros meteorológicos, incluida la temperatura atmosférica, la temperatura del módulo, la velocidad y dirección del viento y la humedad, se consideran parámetros potenciales para estimar la producción de energía fotovoltaica. Se utiliza un número significativo de datos históricos de series de tiempo de producción de energía fotovoltaica y las variables meteorológicas correspondientes para establecer el modelo de pronóstico de producción fotovoltaica. Los datos de la serie histórica se dividen en dos grupos: datos de entrenamiento y datos de prueba. Los datos de entrenamiento se utilizan para entrenar el modelo para predecir valores futuros y los datos de prueba se utilizan para validar el modelo de predicción de fotovoltaica. (Precup et al., 2019).

#### **5.3.1. *Correlación entre las variables de entrada y salida de potencia fotovoltaica***

Las fluctuaciones de los parámetros meteorológicos dependen de la ubicación geográfica y las condiciones meteorológicas. Por lo tanto, no existen parámetros meteorológicos para la generación de energía fotovoltaica en lugares geográficamente diferentes. Por lo tanto, la correlación entre los parámetros meteorológicos y la producción de energía fotovoltaica varía de un lugar a otro. Sin embargo, el rendimiento de un modelo predictivo depende en gran medida de la correlación entre los valores de entrada y salida del modelo. En este caso, es importante estudiar la correlación entre varios insumos meteorológicos como irradiancia solar, temperatura, temperatura del módulo, velocidad y dirección del viento, humedad, producción de energía y cantidad fotovoltaica. Las variables de

entrada con correlación fuerte deben usarse como vectores de entrada para modelos predictivos, y los datos de vectores de entrada con correlación débil deben descartarse.


Figura 6. Irradiancia solar y patrón de salida de energía fotovoltaica para un día al azar.



Fuente: Das et al., 2018

La Figura 6 muestra los patrones de radiación solar y producción de energía fotovoltaica en días aleatorios. En días soleados, es decir, entre semana, la energía fotovoltaica se corresponde muy bien con la curva de radiación solar. La generación de energía fotovoltaica no está estrechamente relacionada, pero sí con la radiación solar en días inusuales como días nublados o lluviosos. Por lo tanto, en todas las condiciones climáticas, se observan patrones similares para la energía fotovoltaica y la radiación solar.

Figura 7. Correlación entre la irradiancia solar y la producción de energía fotovoltaica.




Fuente: Das et al., 2018

La Figura 7 muestra una fuerte correlación positiva (pendiente positiva) entre la radiación solar y la producción de energía solar. La radiación solar es un vector de entrada importante en el desarrollo de modelos adecuados de predicción fotovoltaica debido a su alto coeficiente de correlación (Y. Huang et al., 2010).




Figura 8. Temperatura atmosférica y patrón de producción de energía fotovoltaica para un día en particular.



Fuente: Das et al., 2018

La Figura 8 se muestra el patrón de la temperatura atmosférica y la producción de energía fotovoltaica en un día al azar. El patrón de la temperatura atmosférica y la energía fotovoltaica casi coincide solo con el período de luz diurna. En el período de ausencia de luz natural, la salida de energía fotovoltaica está ausente y no existe ningún impacto de la temperatura atmosférica en la salida de energía fotovoltaica.

Figura 9. Correlación entre la temperatura atmosférica y la potencia fotovoltaica.



Fuente: Das et al., 2018

La Figura 9 muestra la correlación entre temperatura y energía solar. La correlación no es tan fuerte como la radiación, pero no es débil. Por lo tanto, la temperatura puede considerarse como un vector de entrada potencial para establecer con precisión un modelo predictivo de generación fotovoltaica (C. Chen et al., 2011). Los datos de los indicadores de temperatura, velocidad del viento, humedad y nubosidad también se registran en el sistema de adquisición de datos de la planta de energía fotovoltaica. Todas las variables juegan un papel positivo o negativo en la producción de energía. El papel de estas variables depende de su ubicación geográfica. La correlación entre estas variables y la producción de energía depende del papel de cada variable. Al utilizar una gran cantidad de vectores de entrada, puede mejorar la precisión del modelo de predicción de salida. Sin embargo, se agrega la gran cantidad de parámetros de entrada, lo que aumenta el costo computacional. Por lo tanto, es imperativo diseñar un modelo predictivo con el número óptimo de vectores de entrada en función de la correlación. Según los datos y las consideraciones anteriores, existe una correlación muy fuerte entre la generación y la radiación solar en comparación con la temperatura y otras variables meteorológicas. Antes de diseñar un modelo predictivo, necesitamos estudiar la correlación entre otras variables meteorológicas y la producción de energía

fotovoltaica. Por lo tanto, se recomienda el número óptimo y las variables más influyentes para el éxito del modelo de pronóstico.

### **5.3.2. Procesamiento previo de datos de entrada del modelo**

Muchos modelos predictivos utilizaron datos meteorológicos y fotovoltaicos históricos como vectores de entrada. Estos datos pueden contener varios picos y componentes inestables debido a las condiciones climáticas variables e inciertas de la ubicación modelada. Como resultado, estos picos y componentes transitorios en los datos conducen a altos errores de predicción debido a un entrenamiento inadecuado del modelo. Además, los conjuntos de datos de entrada faltantes debido a errores de publicación u otros eventos especiales también afectarán el aumento de los errores de predicción. Al preprocesar los datos de entrada, puede reducir significativamente el problema del entrenamiento falso y los costos computacionales al aprender las muestras correctas. Al procesar previamente los datos de entrada, puede mejorar significativamente la precisión del modelo de pronóstico.

Se han evaluado varios métodos para el procesamiento previo de los datos de entrada de los modelos de pronóstico. Estacionaria, la identificación histórica de LAG (Raza et al., 2016), las series de tiempo sin tendencias (Azadeh et al., 2007), la normalización (Shi et al., 2012), la transformada wavelet (WT) (AlHakeem et al., 2015) y el mapa autoorganizado (SOM) (H.-T. Yang et al., 2014) son los métodos más usados para el procesamiento preliminar de los datos de entrada.

### **5.4. Clasificación de la previsión de generación de energía fotovoltaica**

Los investigadores han categorizado los pronósticos de producción fotovoltaica en varias categorías diferentes basadas en una variedad de factores. Sin embargo, no existen criterios fijos para clasificar los pronósticos de energía fotovoltaica. La mayoría de los investigadores clasifican los pronósticos fotovoltaicos en función de períodos de tiempo de pronóstico, datos históricos de radiación solar, otros modelos

de datos meteorológicos y métodos utilizados para pronosticar. Se realizó una evaluación integral basada en varias clasificaciones predictivas de la producción fotovoltaica, como se muestra a continuación.

#### ***5.4.1. Clasificación de la previsión de energía fotovoltaica basada en el horizonte de previsión***

El momento en el futuro en el que se predice la capacidad de generación fotovoltaica se denomina período de pronóstico. El propósito y la precisión del modelo depende del horizonte de pronóstico. Lipperheide et al., 2015 analizó la evolución de las proyecciones de energía fotovoltaica en diferentes rangos de pronóstico. La precisión del modelo cambia a medida que cambia el período de pronóstico para el mismo modelo con los mismos parámetros. Por lo tanto, debe considerar el período de pronóstico antes de diseñar un modelo adecuado. No existe un criterio claro para clasificación según el período de pronóstico. Sin embargo, la mayoría de los investigadores informan que el pronóstico de la generación de energía fotovoltaica se puede dividir en tres categorías según el tiempo (Lonij et al., 2013):

- Previsión a corto plazo
- Previsión a mediano plazo
- Previsión a largo plazo

##### **5.4.1.1 Previsión a corto plazo**

Los pronósticos a corto plazo se denominan energía solar y ocurren durante una hora, horas, un día o hasta 7 días. Esto asegura que la unidad esté conectada, programada y alimentada. Este tipo de modelo predictivo ayuda en el diseño de un sistema integrado de gestión de energía fotovoltaica. Los pronósticos a corto plazo también mejoran la seguridad de las operaciones de la red.

**5.4.1.2 Previsión a mediano plazo**

Los pronósticos a medio plazo se realizan para una semana a un mes o más. Este tipo de pronóstico simplifica la planificación y programación del mantenimiento del sistema eléctrico al predecir la disponibilidad futura de energía eléctrica.


**5.4.1.3 Previsión a largo plazo**

Los pronósticos a largo plazo para la energía solar varían de un mes a un año. Este tipo de pronóstico de energía fotovoltaica es útil para planificar organizaciones de generación, transmisión y distribución de energía, y para suministrar y suscribir energía.

**5.4.2. *Clasificación de la previsión de energía fotovoltaica basada en datos históricos***

Los métodos de pronóstico se pueden dividir en cuatro categorías basadas en el uso de datos históricos y variables meteorológicas asociadas. Estos modelos se muestran a continuación Figura 10):

Figura 10. Técnicas de previsión basadas en datos históricos.



Fuente: Autor

En el modelo de persistencia, la producción de energía fotovoltaica prevista es igual a la producción de energía real del día anterior a la misma hora. Este enfoque requiere solo datos históricos de salida de energía fotovoltaica para predecir la generación fotovoltaica. Este se utiliza normalmente como modelo de referencia. En los métodos estadísticos, la generación de energía fotovoltaica se predice mediante el análisis estadístico de varias variables de entrada. Por lo tanto, estos métodos utilizan datos de series de tiempo pasadas. Estos métodos se utilizan comúnmente para la previsión a corto plazo de la generación de energía fotovoltaica. Para mejorar la precisión del modelo, estos métodos deben utilizar datos históricos recientes. El requisito del conjunto de datos de entrada para este modelo es menor que para los métodos de aprendizaje automático. Por el contrario, las técnicas de aprendizaje automático requieren grandes conjuntos de datos para predecir con

precisión la producción fotovoltaica. Los modelos de aprendizaje automático son técnicas inteligentes que pueden procesar modelos de datos lineales, no lineales y no estacionarios. La combinación de dos o más técnicas utilizadas para diseñar un modelo predictivo se denomina modelo híbrido. Los modelos combinados combinan los beneficios de cada técnica única para dar mejores resultados que un solo modelo para una variedad de problemas predictivos. (Das et al., 2018)

#### **5.4.3. Clasificación de la previsión de energía fotovoltaica basada en métodos de previsión**

Muchos investigadores han estudiado diferentes formas de predecir la producción fotovoltaica. Proponen y desarrollan diversas tecnologías y modelos para predecir la generación de energía fotovoltaica. (Mellit & Kalogirou, 2008). Los métodos de pronóstico más importantes y populares se describen a continuación.

##### **5.4.3.1 Modelo de persistencia**

El modelo de persistencia es un modelo de pronóstico bastante básicos y se utilizan a menudo para justificar el desempeño de otros modelos de este tipo. La precisión se evalúa comparando los valores predichos con los valores del modelo. En este, la producción de energía fotovoltaica debe permanecer igual a la misma hora el día anterior o el día siguiente. La producción de energía fotovoltaica esperada en las próximas 24 horas se puede explicar de la siguiente manera (X. Yang et al., 2016):

$$P_f(t) = P_{pd}(t)$$

donde  $P_f$  es la potencia pronosticada y  $P_{pd}$  es la potencia de salida del día anterior del día evaluado a la misma hora. Este modelo se utiliza generalmente para la previsión a corto plazo especialmente la previsión de energía eólica, solar y fotovoltaica con una hora de antelación. El error de predicción de este modelo depende de la estabilidad de las condiciones climáticas. Si es poco probable que cambien las condiciones climáticas, la producción fotovoltaica de ayer es un indicador bueno y realista de la producción de energía del día siguiente. Sin

embargo, el período de pronóstico será más largo y la precisión de este modelo disminuirá (Perez et al., 2010).

#### 5.4.3.2 Modelo de media móvil autorregresiva (ARMA)

El modelo ARMA consiste en una combinación de dos modelos básicos, el modelo autorregresiva (AR) y el modelo media móvil (MA). ARMA es adecuado para predecir la producción de energía fotovoltaica a partir de datos deterministas de series de tiempo. La fórmula para el modelo ARMA es: (R. Huang et al., 2012):

$$x(t) = \sum_{i=1}^p a_i x(t-i) + \sum_{j=1}^q b_j e(t-j)$$

donde  $x(t)$  representa la potencia fotovoltaica prevista, que es la suma de las funciones AR y MA. Por tanto,  $p$  y  $q$  indican el orden,  $a_i$  y  $b_i$  son los coeficientes de los modelos AR y MA, respectivamente.  $e(t)$  es el ruido blanco que produce variables aleatorias no correlacionadas con media cero y varianza constante (Rajagopalan & Santoso, 2009). La principal razón de la popularidad del modelo ARMA es su capacidad para extraer las propiedades estadísticas y su adopción del método Box-Jenkins (Boland, 2008). Una extensión de este modelo se utiliza ampliamente para los diferentes modelos de pronóstico con un nivel aceptable de precisión conocido como MA integrado AR (ARIMA) (Box et al., 2015). En el modelo ARIMA, una parte integrada elimina cualquier no estacionariedad de los datos (Wan Ahmad & Ahmad, 2013). Este modelo se puede utilizar de forma independiente o híbrida con otros modelos para predecir la energía fotovoltaica.

#### 5.4.3.3 Método de regresión

La regresión es una técnica estadística que se utiliza para establecer la relación entre variables explicativas y dependientes. En este modelo, la variable dependiente se predice conociendo las variables explicativas. Para la capacidad fotovoltaica prevista se toma como variable dependiente y la variable meteorológica como variable explicativa. Oudjana et al., 2012 pronosticó la predicción fotoeléctrica con



dos modelos de regresión diferentes, regresión lineal simple y regresión lineal múltiple. El modelo de regresión que utiliza la radiación solar y la temperatura como entradas funciona mejor que cuando ambas se toman como entradas. Diseñar un modelo predictivo basado en regresión, esta es la debilidad de este método, requiere un modelo matemático y pocas variables explicativas.

#### **5.4.3.4 Método de suavizado exponencial**

En el suavizado exponencial, el conjunto de ponderaciones desiguales especificadas en los datos históricos se impone a los datos históricos en lugar de las ponderaciones iguales. Sin embargo, el peso de los datos históricos disminuye exponencialmente desde el último al más lejano. El método de suavizado exponencial simple es un método simple, también conocido como MA ponderado exponencial (EWMA)(Brown, 1957).

#### **5.4.3.5 Métodos físicos**


Los métodos de predicción física incluyen una serie de fórmulas matemáticas que describen el estado físico y el movimiento de la atmósfera (Monteiro et al., 2013). Estos se diseñan en función de las características del sistema fotovoltaico, como la ubicación, diversas variables meteorológicas y datos históricos de dirección. Estos modelos pueden ser bastante simples (basados únicamente en la irradiación solar global) o complejos (cuando se incluyen parámetros adicionales). (Dolara et al., 2015). La precisión del modelo de pronóstico físico es mayor cuando las condiciones climáticas son estables. Sin embargo, los cambios repentinos en las variables meteorológicas pueden tener un impacto significativo en el rendimiento previsto. Varios estudios han informado que los métodos de pronóstico físico se han combinado con varios métodos estadísticos e inteligencia artificial para diseñar modelos de pronóstico compuestos que proporcionan una mejor precisión de pronóstico. Estos modelos son muy sensibles a los pronósticos meteorológicos y

deben diseñarse específicamente para instalaciones y ubicaciones específicas. (Gandelli et al., 2014).

#### 5.4.3.6 Red neuronal artificial (ANN)

La ANN ha sido el método más eficaz y ha sido popular entre los investigadores desde la década de 1980. Este método se ha utilizado en muchas aplicaciones de predicción, incluida la solar, con mayor éxito. La ANN se utiliza ampliamente para predecir la energía fotovoltaica debido a la naturaleza no lineal de los datos meteorológicos. Las RNA son más adecuadas que los métodos estadísticos cuando existen relaciones complejas y no lineales entre los datos sin supuestos previos. Los componentes principales de una RNA son la capa de entrada, la capa oculta, la capa de salida, las neuronas y las conexiones. La capa de entrada recibe diversa información de entrada. Las capas ocultas, que pueden constar de una o más capas, analizan la información de entrada. La capa de salida recibe los resultados del análisis y proporciona la salida. Las conexiones unen neuronas en diferentes capas y actualizan sus pesos. Esto está representado por la arquitectura ANN subyacente y un modelo esquemático de procesamiento en neuronas, respectivamente.

Figura 11 (a) Diagrama esquemático de una estructura ANN, que consta de capas de entrada, ocultas y de salida. (b) Un modelo matemático de una celda ANN.



Fuente: Aminzadeh & De Groot, 2006

La figura 11 muestra una neurona dividida en dos partes. La primera parte es una "función de unión" que genera un valor sumando todas las entradas. La segunda parte es la "función de activación". La salida de red se genera agregando una entrada ponderada utilizando la función de activación. Por lo tanto, la función de habilitación de red actúa como una función de compresión para pasar la entrada al módulo de salida. ANN utiliza diferentes tipos de funciones de activación (Hossain et al., 2017).

#### 5.4.3.7 Máquina de vectores de soporte (SVM)

SVM es un método de aprendizaje automático supervisado basado en los principios de minimización de riesgos estructurales (SRM). SRM minimiza el límite superior del riesgo esperado. Por lo tanto, SVM puede minimizar los errores en los datos de entrenamiento. SVM fue desarrollado por Vapnik para resolver problemas de clasificación. Sin embargo, las SVM se han ampliado recientemente al ámbito de los problemas de regresión. Una aplicación para SVM en regresión de series de tiempo se llama Regresión de vectores de soporte (SVR). La predicción fotoeléctrica es un problema típico en el análisis de series de tiempo. Por tanto, la RVS es el método adecuado en este caso. (Hu et al., 2014; Müller et al., 1997). El algoritmo SVR es un algoritmo de regresión no lineal. La muestra de datos de la serie temporal de entrada se asigna a un espacio de características más grande mediante el mapeo no lineal, donde se realiza la regresión lineal. Para desarrollar un modelo basado en SVR para predecir la producción fotovoltaica, tres parámetros controlan el rendimiento del modelo. Estos parámetros son la penalización ( $C$ ) que define la penalización del error de estimación, el radio de la tubería ( $\epsilon$ ) que define los datos en la tubería que se ignoran en la regresión y el parámetro multiplicador. Para desarrollar el modelo predictivo correcto, es necesario elegir el valor correcto y el parámetro multiplicador de  $C$ . El rendimiento de este modelo depende en gran medida de la elección de los tres parámetros, lo que constituye una limitación de este método. (Cherkassky & Ma, 2004).

#### 5.4.3.8 Modelo híbrido

El rendimiento de un solo modelo no es más preciso para pronosticar la generación de energía fotovoltaica en diferentes casos. Este problema se puede atribuir a la limitación de una técnica independiente. La combinación de dos o más técnicas, lo que se conoce como modelo híbrido, es la mejor solución para esos casos. Estos tipos de modelos se han utilizado para varias aplicaciones de predicción para lograr una mayor precisión. Una de las principales motivaciones de estos modelos es explorar las posibles combinaciones de diferentes topologías para mejorar la precisión del pronóstico. Los modelos híbridos pueden garantizar un mejor rendimiento de pronóstico aprovechando cada topología individual. Los modelos híbridos han logrado mejores resultados que las técnicas independientes para resolver el problema de pronóstico de energía fotovoltaica. El modelo de inferencia difusa con RNN se ha aplicado con éxito en la previsión de energía fotovoltaica (Cherkassky & Ma, 2004). En este caso, se ha utilizado un modelo de inferencia difusa para suavizar los datos meteorológicos, que se utilizan para pronosticar la generación de energía fotovoltaica. El modelo de pronóstico híbrido difuso-GA también ha mostrado buenos resultados en el pronóstico de energía fotovoltaica (S.-M. Chen et al., 2013). En varios modelos de pronóstico híbrido, la transformada wavelet (WT) se utiliza con técnicas convencionales o de inteligencia artificial en el pronóstico de energía fotovoltaica. En tal caso, WT se utiliza para eliminar el ruido de los datos de entrada. Los datos meteorológicos posteriores a WT se han utilizado como entrada de modelos de previsión basados en ANN y SVM, que predijeron la generación de energía fotovoltaica con un error mínimo (Colak & Qahwaji, 2007). Sin embargo, la complejidad computacional aumenta en un modelo híbrido debido a la utilización de dos o más técnicas. El rendimiento de un modelo híbrido depende del rendimiento de un modelo único individual. La precisión del modelo híbrido se ve afectada por la selección de una sola técnica que puede funcionar mal, lo cual es una limitación del modelo híbrido.

### 5.5. Análisis de desempeño de diferentes métodos de pronóstico

El modelo de persistencia, también conocido como modelo elemental, se ha utilizado ampliamente como punto de referencia para otros modelos de previsión de energía fotovoltaica simples y complejos. Este modelo puede proporcionar un pronóstico preciso de la generación de energía fotovoltaica para condiciones climáticas soleadas similares de días pronosticados vecinos (Xiyun & Song, 2014). La principal debilidad de este modelo es que la precisión disminuye significativamente con el aumento de la cobertura de nubes y cuando la duración es superior a 1 h. Por lo tanto, este método no es adecuado como modelo de pronóstico; sin embargo, proporciona un punto de referencia que se puede utilizar ampliamente para estandarizar el desempeño de la previsión.

de otros modelos (Yadav et al., 2015).

ARMA es un ejemplo de un método lineal para el modelado estadístico para correlacionar datos históricos de series de tiempo. Este método puede incorporar diferentes tipos de datos de series de tiempo y extraer propiedades estadísticas de ellos. Sin embargo, los datos de la serie temporal deben ser estacionarios. El método ARMA se mejoró con la introducción del método ARIMA. Donde esta última es una extensión de ARMA con una capacidad adicional para datos de series de tiempo no estacionarios y captura transiciones nítidas en irradiancia con mayor precisión. Esta capacidad para capturar datos irregulares es deseable cuando el patrón climático que se predice es muy irregular. Sin embargo, en comparación con ARMA, ARIMA es más computacionalmente intensivo debido a la inclusión de una función de suma e integración en el método (Reikard, 2009).

ANN se desarrolló como un cambio de algoritmos lineales a una solución no lineal. Este método es muy popular debido a su efectividad para ser entrenado, lo que permite una mayor precisión. ANN tiene capacidades de autoadaptación, tolerancia a fallas, robustez y fuertes inferencias. El modelado basado en ANN supera a los

modelos matemáticos convencionales en términos de precisión y adaptabilidad. El inconveniente de usar ANN es que aumenta significativamente la complejidad del modelo debido a la naturaleza del uso de una arquitectura de red de múltiples capas. Además, las NN requieren un conjunto de datos iniciales aleatorios que pueden reducir la confiabilidad de los resultados pronosticados (Leva et al., 2017).

La lógica difusa (FL) proporciona un método sólido y ventajoso para modelar parámetros y se basa en la regla de inferencia. FL se ha utilizado para modelos de predicción a medio plazo, porque maneja la incertidumbre de los datos del mundo real. Además, las reglas difusas tienen una base lingüística y permiten un enfoque más estadístico de la toma de decisiones (Ghofrani et al., 2016). El método FL, sin embargo, requiere un tiempo de ejecución prolongado en comparación con SVM o varios nodos de prueba que limitan su rendimiento (P. Chen et al., 2016).

SVM es un modelo no lineal predominante y altamente flexible que se ha utilizado en la predicción de energía eólica y recientemente para la predicción de la generación de energía fotovoltaica. El punto fuerte de SVM está en su capacidad de aprender sin depender en gran medida de conocimientos previos, a diferencia de ANN. SVM permite la simplificación de los complejos problemas matemáticos que pueden estar relacionados con la predicción de PV. Sin embargo, SVM es muy sensible a los parámetros utilizados para desarrollar un modelo de pronóstico (Müller et al., 1997).

Los errores de la previsión a corto plazo de la generación de energía fotovoltaica deberían ser inferiores al 20% en RMSE. El modelo híbrido se ha utilizado ampliamente para mejorar la precisión del pronóstico de la generación de energía fotovoltaica. Optimización del modelo de previsión (Daye, 2011).

## 6. CONCLUSIONES

- La integración de la energía fotovoltaica en la red ha sido el foco de investigación debido al cambio climático reciente y al calentamiento global. La previsión fotovoltaica precisa es esencial debido a la necesidad de satisfacer la creciente demanda de energía, mitigar el cambio climático y estabilizar los sistemas de red por lo cual las técnicas de inteligencia artificial son fundamentales para un pronóstico eficiente.
- Los resultados muestran que la precisión del modelo mejora cuando el coeficiente de correlación con el input-output utilizado en el modelo es alto. De igual manera, los resultados sugieren que los modelos de pronóstico dependen del período de pronóstico, los datos disponibles y el método utilizado. En la mayoría de los casos, los modelos de predicción de energía fotovoltaica se desarrollan basándose en pronósticos a corto plazo. La precisión varía a medida que cambia el período de pronóstico, incluso si los parámetros del modelo de pronóstico son los mismos.

## 7. RECOMENDACIONES

Se recomienda estudiar el efecto de combinar distintos modelos de previsión con distintos conjuntos de datos de entrada. De igual manera, implementar modelos híbridos para el pronóstico de la irradiación solar. Esto con el fin de hacer un análisis más amplio del ajuste de los parámetros para los modelos. De igual forma, se recomienda estudiar el efecto del uso de distintas metodologías de preprocesamiento del conjunto de datos inicial y agrupación de los datos en la salida del algoritmo.



## 8. REFERENCIAS BIBLIOGRÁFICAS

- AlHakeem, D., Mandal, P., Haque, A. U., Yona, A., Senjyu, T., & Tseng, T.-L. (2015). A new strategy to quantify uncertainties of wavelet-GRNN-PSO based solar PV power forecasts using bootstrap confidence intervals. *2015 IEEE Power & Energy Society General Meeting*, 1–5.
- Aminzadeh, F., & De Groot, P. (2006). *Neural networks and other soft computing techniques with applications in the oil industry*. Eage Publications.
- Azadeh, A., Ghaderi, S. F., & Sohrabkhani, S. (2007). Forecasting electrical consumption by integration of neural network, time series and ANOVA. *Applied Mathematics and Computation*, 186(2), 1753–1761.
- Boland, J. (2008). *Time series modeling of solar radiation. Modelling Solar Radiation at the Earth's Surface, V. Badescu*. Springer-Verlag Berlin Heidelberg.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- Brown, R. G. (1957). Exponential smoothing for predicting demand. *Operations Research*, 5(1), 145.
- Burnham, J. F. (2006). Scopus database: a review. *Biomedical Digital Libraries*, 3(1), 1–8.
- Castaño-Gómez, M., & García-Rendón, J. J. (2020). Análisis de los incentivos económicos en la capacidad instalada de energía solar fotovoltaica en Colombia. *Lecturas de Economía*, 93, 23–64.
- Chen, C., Duan, S., Cai, T., & Liu, B. (2011). Online 24-h solar power forecasting based on weather type classification using artificial neural network. *Solar Energy*, 85(11), 2856–2870.
- Chen, P., Yuan, L., He, Y., & Luo, S. (2016). An improved SVM classifier based on double chains quantum genetic algorithm and its application in analogue circuit diagnosis. *Neurocomputing*, 211, 202–211.

- Chen, S.-M., Chang, Y.-C., Chen, Z.-J., & Chen, C.-L. (2013). Multiple fuzzy rules interpolation with weighted antecedent variables in sparse fuzzy rule-based systems. *International Journal of Pattern Recognition and Artificial Intelligence*, 27(05), 1359002.
- Cherkassky, V., & Ma, Y. (2004). Practical selection of SVM parameters and noise estimation for SVM regression. *Neural Networks*, 17(1), 113–126.
- Colak, T., & Qahwaji, R. (2007). Automatic sunspot classification for real-time forecasting of solar activities. *2007 3rd International Conference on Recent Advances in Space Technologies*, 733–738.
- Darlington, K. (2000). *The essence of expert systems*. Prentice Hall.
- Das, U. K., Tey, K. S., Seyedmahmoudian, M., Mekhilef, S., Idris, M. Y. I., Van Deventer, W., Horan, B., & Stojcevski, A. (2018). Forecasting of photovoltaic power generation and model optimization: A review. *Renewable and Sustainable Energy Reviews*, 81, 912–928.
- Daye, T. (2011). Managing intermittency: standards and recommended practices in solar power forecasting. *ERCOT Emerging Technol.*
- Dolara, A., Grimaccia, F., Leva, S., Mussetta, M., & Ogliari, E. (2015). A physical hybrid artificial neural network for short term forecasting of PV plant power output. *Energies*, 8(2), 1138–1153.
- Dorigo, M. (1992). *The metaphor of the ant colony and its application to combinatorial optimization*. PhD thesis, Politecnico di Milano, Italy.
- Franklin, J. (2005). The elements of statistical learning: data mining, inference and prediction. *The Mathematical Intelligencer*, 27(2), 83–85.
- Gandelli, A., Grimaccia, F., Leva, S., Mussetta, M., & Ogliari, E. (2014). Hybrid model analysis and validation for PV energy production forecasting. *2014 International Joint Conference on Neural Networks (IJCNN)*, 1957–1962.
- Ghofrani, M., Ghayekhloo, M., & Azimi, R. (2016). A novel soft computing framework for solar radiation forecasting. *Applied Soft Computing*, 48, 207–216.

Gómez-Luna, E., Fernando-Navas, D., Aponte-Mayor, G., & Betancourt-Buitrago, L.

- A. (2014). Metodología para la revisión bibliográfica y la gestión de información de temas científicos, a través de su estructuración y sistematización. *Dyna*, 81(184), 158–163.
- Hales, D. (2020). Renewables 2020 global status report. *Rep. Paris*, 120–130.
- Hossain, M. S., Ong, Z. C., Ismail, Z., Noroozi, S., & Khoo, S. Y. (2017). Artificial neural networks for vibration based inverse parametric identifications: A review. *Applied Soft Computing*, 52, 203–219.
- Hu, J., Gao, P., Yao, Y., & Xie, X. (2014). Traffic flow forecasting with particle swarm optimization and support vector regression. *17th International Ieee Conference on Intelligent Transportation Systems (Itsc)*, 2267–2268.
- Huang, R., Huang, T., Gadh, R., & Li, N. (2012). Solar generation prediction using the ARMA model in a laboratory-level micro-grid. *2012 IEEE Third International Conference on Smart Grid Communications (SmartGridComm)*, 528–533.
- Huang, Y., Lu, J., Liu, C., Xu, X., Wang, W., & Zhou, X. (2010). Comparative study of power forecasting methods for PV stations. *2010 International Conference on Power System Technology*, 1–6.
- Kaushika, N. D., Mishra, A., & Rai, A. K. (2018a). Fundamentals of Photovoltaic Generation: A Review. *Solar Photovoltaics*, 27–41.
- Kaushika, N. D., Mishra, A., & Rai, A. K. (2018b). *Solar photovoltaics: technology, system design, reliability and viability*. Springer.
- Leva, S., Dolara, A., Grimaccia, F., Mussetta, M., & Ogliari, E. (2017). Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power. *Mathematics and Computers in Simulation*, 131, 88–100.
- Lipperheide, M., Bosch, J. L., & Kleissl, J. (2015). Embedded nowcasting method using cloud speed persistence for a photovoltaic power plant. *Solar Energy*, 112, 232–238.
- Lonij, V. P. A., Brooks, A. E., Cronin, A. D., Leuthold, M., & Koch, K. (2013). Intra-hour forecasts of solar power production using measurements from a network of irradiance sensors. *Solar Energy*, 97, 58–66.

- Manaris, B. (1998). Natural language processing: A human-computer interaction perspective. In *Advances in Computers* (Vol. 47, pp. 1–66). Elsevier.
- Mandal, P., Madhira, S. T. S., Meng, J., Pineda, R. L., & others. (2012). Forecasting power output of solar photovoltaic system using wavelet transform and artificial intelligence techniques. *Procedia Computer Science*, 12, 332–337.
- Mellit, A., & Kalogirou, S. A. (2008). Artificial intelligence techniques for photovoltaic applications: A review. *Progress in Energy and Combustion Science*, 34(5), 574–632.
- Metropolis, N., Rosenbluth, A. W., Rosenbluth, M. N., Teller, A. H., & Teller, E. (1953). Equation of state calculations by fast computing machines. *The Journal of Chemical Physics*, 21(6), 1087–1092.
- Monteiro, C., Fernandez-Jimenez, L. A., Ramirez-Rosado, I. J., Muñoz-Jimenez, A., & Lara-Santillan, P. M. (2013). Short-term forecasting models for photovoltaic plants: Analytical versus soft-computing techniques. *Mathematical Problems in Engineering*, 2013.
- Müller, K.-R., Smola, A. J., Rätsch, G., Schölkopf, B., Kohlmorgen, J., & Vapnik, V. (1997). Predicting time series with support vector machines. *International Conference on Artificial Neural Networks*, 999–1004.
- Oudjana, S. H., Hellal, A., & Mahamed, I. H. (2012). Short term photovoltaic power generation forecasting using neural network. *2012 11th International Conference on Environment and Electrical Engineering*, 706–711.
- Perez, R., Kivalov, S., Schlemmer, J., Hemker Jr, K., Renné, D., & Hoff, T. E. (2010). Validation of short and medium term operational solar radiation forecasts in the US. *Solar Energy*, 84(12), 2161–2172.
- Precup, R., Kamal, T., & Hassan, S. Z. (2019). *Solar Photovoltaic Power Plants*. Springer.
- Rajagopalan, S., & Santoso, S. (2009). Wind power forecasting and error analysis using the autoregressive moving average modeling. *2009 IEEE Power & Energy Society General Meeting*, 1–6.

- Raza, M. Q., Nadarajah, M., & Ekanayake, C. (2016). On recent advances in PV output power forecast. *Solar Energy*, 136, 125–144.
- Reikard, G. (2009). Predicting solar radiation at high resolutions: A comparison of time series forecasts. *Solar Energy*, 83(3), 342–349.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3(3), 210–229.
- Shi, J., Lee, W.-J., Liu, Y., Yang, Y., & Wang, P. (2012). Forecasting power output of photovoltaic systems based on weather classification and support vector machines. *IEEE Transactions on Industry Applications*, 48(3), 1064–1069.
- Soman, S. S., Zareipour, H., Malik, O., & Mandal, P. (2010). A review of wind power and wind speed forecasting methods with different time horizons. *North American Power Symposium 2010*, 1–8.
- Sutton, R. S., & Barto, A. G. (1998). Reinforcement learning: an introduction MIT Press. Cambridge, MA, 22447.
- Thede, S. M. (2004). An introduction to genetic algorithms. *Journal of Computing Sciences in Colleges*, 20(1), 115–123.
- Van Eck, N. J., & Waltman, L. (2013). VOSviewer manual. *Leiden: Univeristeit Leiden*, 1(1), 1–53.
- Wan Ahmad, W. K. A., & Ahmad, S. (2013). Arima model and exponential smoothing method: A comparison. *AIP Conference Proceedings*, 1522(1), 1312–1321.
- Xiyun, Y., & Song, C. (2014). A combination method in photovoltaic power forecasting based on the correlation coefficient. *2014 IEEE 5th International Conference on Software Engineering and Service Science*, 706–709.
- Yadav, H. K., Pal, Y., & Tripathi, M. M. (2015). Photovoltaic power forecasting methods in smart power grid. *2015 Annual IEEE India Conference (INDICON)*, 1–6.
- Yang, H.-T., Huang, C.-M., Huang, Y.-C., & Pai, Y.-S. (2014). A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output. *IEEE Transactions on Sustainable Energy*, 5(3), 917–926.

- Yang, X., Ren, J., & Yue, H. (2016). Photovoltaic power forecasting with a rough set combination method. *2016 UKACC 11th International Conference on Control (CONTROL)*, 1–6.
- Youssef, A., El-Telbany, M., & Zekry, A. (2017). The role of artificial intelligence in photo-voltaic systems design and control: A review. *Renewable and Sustainable Energy Reviews*, 78, 72–79.
- Zadeh, L. A. (1996). Fuzzy sets. In *Fuzzy sets, fuzzy logic, and fuzzy systems: selected papers by Lotfi A Zadeh* (pp. 394–432). World Scientific.