

# Solar Radiation Prediction Using Machine Learning Techniques: A Review

E. Obando, S. Carvajal, and J. Pineda

**Abstract**—Solar radiation estimation determines how much energy the sun provides to a particular region. This radiation is the primary energy source of conversion in photovoltaic plants and solar thermal power plants. The incident radiation is not constant and depends on climatic data, which results in an intermittency in its behavior and changes in the production of electrical energy are observed. This justifies the development of a tool for predicting and estimating incident radiation in order to foresee changes in the performance of photovoltaic generation systems.

This paper presents an analysis and review of the literature published in the Science Direct and IEEE databases since 1990, from the point of view of techniques application for the estimation of the primary solar resource. These techniques are classified according to the nature of the model from numerical and analytical approaches to Machine Learning. These approaches use different databases, inputs and mathematical relationships to establish dependencies among solar radiation, longitude, latitude and climatic parameters. In this paper, the selection criteria and behavior of the models are identified from the linearity treatment of the database to be used, the number of entries, the deviation between the value that is predicted and the test portion of the set of data that evaluate their behavior and provide decision tools for their use. Many authors apply Machine Learning to estimation both with unitary predictors and with hybrid models that profit from their potential.

**Index Terms**—Hybrid models, Machine Learning, Photovoltaic generation systems, Radiation Forecasting.

## I. INTRODUCCIÓN

EN los últimos 20 años existe un aumento en el uso de Fuentes No Convencionales de Energía Renovable (FNCER) en Colombia y en el mundo, con trabajos que registran la masificación de este tipo de fuentes y visibiliza avances en generación eléctrica [1]. Dentro de estas fuentes no convencionales esta la energía solar, la cual aprovecha directamente la radiación incidente del sol para transformarla en energía eléctrica en el caso de sistemas solares fotovoltaicos (FV) y térmica en el caso de las plantas de calentamiento. En los sistemas FV, la capacidad de generación de electricidad solar está estrechamente ligada a condiciones climáticas en la región donde se quiera implementar el sistema [2], [3].

E.D.Obando, Departamento de Ingeniería Eléctrica Electrónica y Computación, Manizales 17001 CO, Universidad Nacional de Colombia, Manizales, Colombia, (email: edobandop@unal.edu.co).

S.X.Carvajal Q, Departamento de Ingeniería Eléctrica Electrónica y Computación, Manizales 17001 CO, Universidad Nacional de Colombia, Manizales, Colombia, (email: sxcarvajalq@unal.edu.co).

J. Pineda Agudelo, Departamento de Matemáticas y Estadística, Manizales 17001 CO, Universidad Nacional de Colombia, Manizales, Colombia, (email: jpinedaa@unal.edu.co).

La fluctuación del clima tiene directa relación con la producción de electricidad, lo que genera efectos adversos como: variaciones en la tensión [4] y baja calidad de la potencia [5].

Para la estimación de radiación existen dos tipos de aproximación. La primera son las aproximaciones numéricas y analíticas basadas en ecuaciones y relaciones entre datos climáticos [6], [7], para obtener como resultado un modelo determinístico. La segunda es el Aprendizaje Automático, en inglés Machine Learning (ML), que se centra en buscar modelos estocásticos basados en datos climáticos históricos con el fin de establecer relaciones entre estos y la radiación solar [8], [9].

Los modelos de Aprendizaje Automático son muy versátiles en su aplicación en FNCER. En el recurso eólico, se usan en la predicción de velocidad del viento como recurso primario para instalación de parques eólicos que se integrarán a la red [10], en donde se tiene en cuenta localización geográfica representada por latitudes y longitudes muy similares entre las ciudades de estudio además de las relaciones entre datos climáticos locales [10], [11].

En sistemas solares FV, los modelos de Aprendizaje Automático se integran como herramientas que soportan la predicción de la operación de estos sistemas al evaluar la fluctuación en entrega de potencia al tener en cuenta la tecnología que se utiliza al captar el recurso primario y transformarlo en electricidad [12]. Además de ser herramientas en la predicción de potencia, los soportan las decisiones de instalación de plantas solares FV a gran escala y sus impactos [13], [14].

En este artículo se identifican y analizan antecedentes de aplicación de técnicas de Aprendizaje Automático en predicción de radiación solar. Además de establecer criterios de aplicación de estas técnicas teniendo en cuenta factores como: uso de base de datos, horizonte de predicción, localización geográfica, comparación entre técnicas y evolución de las mismas en el tiempo.

La revisión fue realizada a partir de la década de 1990 debido a un crecimiento sustancial en el interés de estudiar redes neuronales [6] las cuales son las primeras aproximaciones que usan conceptos asociados al Aprendizaje Automático y la Inteligencia Artificial (IA) aplicados a la predicción, diseño y dimensionamiento de sistemas solares fotovoltaicos [15]–[17]. La estructura del documento es la siguiente: en la segunda sección se muestran las aproximaciones disponibles para determinar radiación solar incidente. En la tercera se describen y clasifican las técnicas de Aprendizaje Automático más usadas en predicción solar desde el punto de vista de datos de entrada

para generar el modelo y criterios de uso. En la cuarta se presentan enfoques híbridos de estimación de radiación que usa técnicas propias del Aprendizaje Automático y las etapas del proceso de predicción. Finalmente se presentan las conclusiones.

## II. EVOLUCIÓN EN EL USO DE MODELOS PARA PREDECIR RADIACIÓN SOLAR INCIDENTE

La determinación de radiación solar se hace mediante varios métodos. Sin embargo, los modelos para predecir radiación fueron evolutivos. Las primeras aproximaciones son las de tipo numérico [18]–[20], seguidos por los analíticos donde están: procesamiento de imágenes [21]–[23], estadístico [24]–[26] y finalmente el uso de técnicas de Aprendizaje Automático [27]–[29]. Según los anteriores trabajos, el desarrollo del modelo final depende de las relaciones que se presentan entre la radiación incidente y parámetros climáticos. Se propone en este trabajo la clasificación de técnicas por el tipo de datos que hacen de entrada al modelo. De acuerdo a [30] y [31] los modelos se clasifican en:

El modelo de radiación solar y los valores, en cualquier escala de tiempo, está basado en parámetros meteorológicos: Temperatura de aire,  $T_a$ , humedad relativa  $RH$ , índice de claridad,  $CI$ , velocidad del viento  $V_v$ , nubosidad,  $K_i$  y presión,  $P$ . Además de las coordenadas geográficas, longitud y latitud. Esta aproximación es del tipo  $(G_i) = f(\dots T_a - 2, T_a - 1, T_a; \dots RH - 2; RH - 1; RH, \dots V_v - 2, V_v - 1, V_v; \dots K_i - 2, K_i - 1, K_i, \dots P - 2, P - 1, P; \dots CI - 2, CI - 1, CI; Lat; Long)$  y se le denomina *modelo con datos estructurados*.

-Una segunda aproximación, denominada *modelo con datos endógenos*, utiliza valores históricos de radiación para generación del modelo. Este método se formula como  $G(i + p) = f(\dots, G_{i+p-2}, G_{i+p-1}, \dots, G_i)$ . Los datos futuros ( $t + p$ ) están basados en datos históricos de la forma  $\dots (t + p - 2, t + p - 1, \dots, t)$ .

-Una última aproximación es una combinación de las dos primeras relaciones, se denomina *modelo con datos exógenos*. Se encuentran relaciones del tipo  $G(i + p) = f(G_{i+p-1}, G_{i+p-2}, \dots, G_i, \dots T_a - 2, T_a - 1, T_a; \dots RH - 2; RH - 1; RH, \dots V_v - 2, V_v - 1, V_v; \dots K_i - 2, K_i - 1, K_i, \dots P - 2, P - 1, P; \dots CI - 2, CI - 1, CI; Lat; Long)$ . En este caso las entradas son datos de radiación solar históricos y otros parámetros meteorológicos.

A continuación, se amplía la aplicación de aproximaciones numéricas-analíticas y se tiene en cuenta el objetivo de predicción y las relaciones matemáticas a las que llegaron los autores.

### A. Aproximaciones Numéricas

Por medio de ecuaciones explícitas la generación de valores de radiación solar, por hora, día, mes y por año. En las primeras aproximaciones, la radiación es la variable propia del modelo, y se define lo que se denomina *índice de claridad (Clearnex Index)*. En estos trabajos se propone un modelo empírico que usa coeficientes de relación entre la radiación total y la radiación en día despejado [25], [32]–[35]. En este tipo de aproximaciones no se muestra relación entre radiación y otros datos climáticos [33]. Sin embargo, en otro estudio se establece un nuevo método para determinar coeficientes que mejoren la

precisión del modelo de radiación solar usado anteriormente. Este método prueba, en diferentes localizaciones y estaciones, los coeficientes que ajusten mejor a la radiación medida [32].

Una de las primeras aproximaciones numéricas es el modelo de Angstrom, en el cual se optimiza el cálculo del valor de los coeficientes por medio de una regresión lineal [33]. Además de asumir el carácter lineal de la radiación, se linealiza por periodos de tiempo.

En general en estos trabajos se trata la radiación solar desde el punto de vista de aproximaciones lineales y el modelo generado depende fuertemente de los coeficientes de relación [35]. Existen modelos numéricos empíricos que empiezan a relacionar la radiación solar incidente en el lugar con parámetros como temperatura, latitud, longitud entre otros [36].

El problema de la estimación de radiación dependiente de datos climáticos se aborda desde el concepto físico de radiación y su descomposición en tres tipos de radiación: directa, difusa y albedo. Se encuentran relaciones entre la localización geográfica y las condiciones topográficas de un área determinada [37]. En el modelo propuesto se calculan coeficientes de relación a partir de la combinación de dos modelos preestablecidos.

En otros trabajos se desarrolla una relación matemática entre la radiación incidente, el ángulo cenit, se tiene en cuenta la localización geográfica y variaciones del clima [38], [39]. Estas aproximaciones son de carácter lineal en las que coeficientes son calculados mediante regresiones lineales y curvas de aproximación. En estos trabajos se presenta un común denominador al usar datos endógenos para establecer modelos, lo que ocasiona que cada modelo sea aplicado localmente donde se realizó el estudio.

En otro tipo de estudios se aborda el problema no lineal en la construcción de modelos de radiación incidente. En estos trabajos se utiliza: modelos autoregresivos lineales de media móvil (ARIMA). Este está soportado por una distribución gaussiana que establece relaciones entre la radiación y parámetros climáticos externos [34], [40]. Este proceso se realiza mediante la aproximación por curvas suaves al comportamiento real de la radiación.

En [41], se desarrolló una aproximación para determinar radiación solar media por horas. Esta aproximación está basada en una metodología empírica en la cual implementa una función denominada función de transferencia. Esta función es suave a trozos y se caracteriza para 3 fases: ascenso, descenso y valor pico. El modelo presenta una ecuación con coeficientes numéricos que son calibrados mediante la aplicación de datos medidos en una ciudad.

### B. Aproximaciones Analíticas

Las primeras aproximaciones analíticas son las estadísticas seguidas por las que utilizan procesamiento de imágenes. Se consideran analíticas puesto que tratan la radiación como una señal que puede ser descompuesta y estudiada que será entrada para generar un modelo similar al histórico. En [14], [15], los modelos desarrollados se caracterizan por tratar los datos de radiación como una función de densidad de probabilidades. Esta se calcula mediante datos históricos, con aproximaciones numéricas de tipo gaussiano para estimar dicha función. Esto genera un modelo característico para cada mes de aplicación. Un caso especial se presenta en [26] donde se evalúa el

desempeño de un modelo híbrido. En este se usa una aproximación por medio de distribución gaussiana del índice de claridad, para luego discretizar la señal en el dominio de la frecuencia con el uso de wavelet. Esto hace que el modelo estadístico híbrido tenga un desempeño un 15% mejor con respecto al algoritmo simple [25], [26].

En las aproximaciones que usan procesamiento de imágenes, se estima la radiación tratándola como un arreglo bidimensional que posee píxeles en filas y columnas. En trabajos como [22] se desarrolla un modelo que predice radiación directa en base a imágenes satelitales y movimiento de nubes, tratándolas como vectores de movimiento. Este modelo se desarrolla sobre estaciones climáticas. En periodos futuros largos, meses y años, la precisión del modelo es limitada, esto debido a píxeles de la imagen y resolución satelital.

Ciertas aproximaciones desarrollan un modelo bidimensional de representación de la radiación solar incidente [43]. Se genera una representación matricial con horas y días que corresponden a las columnas y valores de radiaciones que corresponden a las filas. Para determinar el comportamiento del modelo se desarrollan filtros lineales cuya función es obtener la correlación necesaria entre el modelo y los valores predichos.

En trabajos como [44], [45] se utiliza un algoritmo ARIMA para predecir radiación en 6 ciudades. Los resultados muestran que existen ventajas en el desempeño de ARIMA sobre NN en el caso de *timestep* de datos superiores a 5 minutos, de lo contrario en resoluciones de datos altas (entre 1 minuto y 4 minutos) NN presenta mejor comportamiento. Esto conduce a concluir que la elección del modelo depende directamente del *dataset* de entrada. ARIMA modela de mejor manera el ciclo de radiación diaria, en dataset de larga duración, esto no hace necesaria una etapa de entrenamiento, debido al comportamiento lineal de la radiación en la base de datos. El costo computacional también es evaluado en este trabajo. Se muestra que ARIMA tiene menor costo computacional, en parte debido a las aproximaciones lineales con las que desarrolla la estimación.

En [46] usa ARMA como una parte del modelo. Modela la radiación incidente como una superposición de componentes

lineales y no lineales. Este modelo tiene desventajas puesto que tiene un desempeño aceptable en intervalos donde la radiación es constante y casi lineal, pero en cambios bruscos el error es superior al 30% del valor medido. En [47] hace un estudio comparativo donde se considera el horizonte de predicción. Según el autor la comparación entre ARMA y MLP tienen un comportamiento similar para horizontes de día y hora siguiente. Además, tienen valores de error similares en las etapas de validación y prueba cuando se comparan con otros algoritmos.

En un estudio posterior [48], confirma lo que se muestra en estudios previos. La metodología ARMA usada es una herramienta muy eficiente para generar pronósticos puntuales a muy corto plazo. El modelo supera en aproximadamente un 20% a los algoritmos estadísticos usados en la comparación.

La Tabla I muestra los principales avances y los desafíos encontrados en estas investigaciones.

En estos trabajos los métodos de evaluación de precisión son diferentes. Algunos como el coeficiente de correlación (R) coeficiente de correlación cuadrado (R<sup>2</sup>) y el error cuadrático medio (RMSE) [41], [60], [61] se utilizan a menudo. Otro tipo son: error de desviación estándar (MBE), error absoluto (MAE) y error relativo medio (MAPE) [55] usados no tan frecuentemente.

Otra característica en estos trabajos es el tiempo de evaluación del modelo. Algunos de ellos analizaron la precisión del modelo durante un periodo de uno o varios meses, incluso años, además de tener presente las estaciones climáticas y la variabilidad asociada. En estas condiciones es difícil hacer comparaciones. Existen documentos como [62] en el cual se lleva a cabo una revisión de la literatura sobre la precisión de pronóstico y técnicas aplicadas a sistemas de energía renovable, principalmente solar y eólica. En la siguiente sección se presentan las diferentes metodologías utilizadas que tienen su base en el ML usadas para predecir radiación global y los parámetros para estimar los rendimientos del modelo.

En la Fig. 1, se muestran las técnicas para estimar radiación solar y algunos trabajos clasificados.

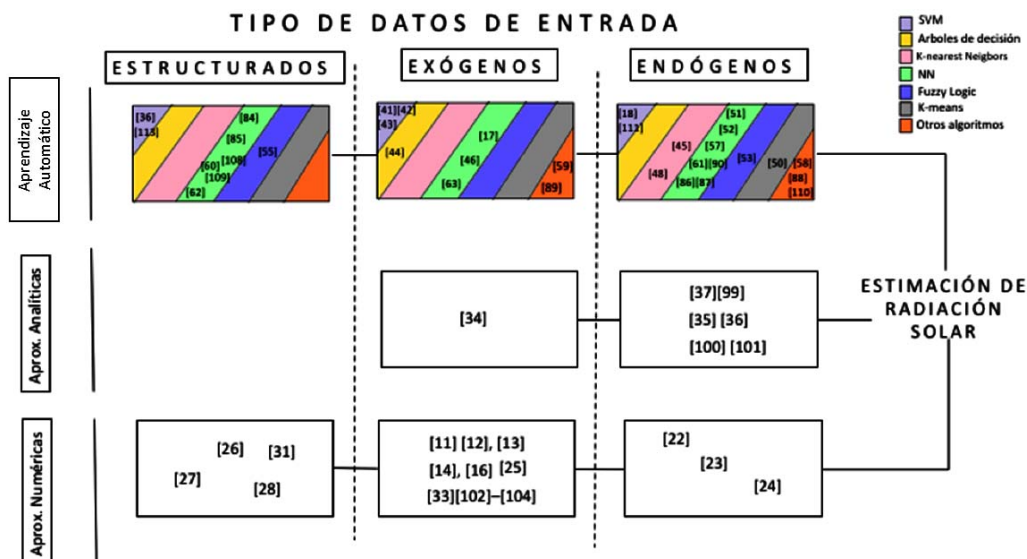


Fig. 1. Clasificación de técnicas de estimación de radiación sol. Fuente: Propia

TABLA I  
 AVANCES Y DESAFÍOS EN APROXIMACIONES NUMÉRICAS-ANALÍTICAS. FUENTE: PROPIA

Referencias	Aportes	Desafíos	Tipo de datos de entrada
[24], [26]	Introducción de una función de densidad que hace las veces de aproximación.	No determina el valor de las demás entradas considera una sola (radiación) en el modelo Utiliza reconstrucción solar en intervalos predefinidos. Al usar la diferencia de radiación entre cielo despejado y radiación actual, la precisión disminuye en horizontes de predicción largos.	Exógenos
[37]	Primera aproximación para separar componentes de radiación. Considera la topografía del terreno como factor que cambia el modelo desarrollado.	Mejorar precisión en superficies irregulares. Considerar nubes como cuerpos estáticos.	Endógeno
[41]	A partir de históricos de una ciudad predice radiación en 4 ciudades. Primeros trabajos donde se hace pre procesamiento a los datos de entrada. Aproxima el valor de radiación por medio de funciones.	Error con datos medidos superior al 20% en la estimación por hora. En predicción anual no estima de forma precisa los valores de radiación. Correlación entre datos muy baja, aproximadamente del 60% Dataset limitado realiza pronósticos por intervalos.	Estructurado
[49]	Usa relación de coeficientes para eliminar el efecto de la elevación. Clasificación de días: Soleado o nublado. En la estimación horaria error es alrededor 5%	Usa percentiles que dividen el dataset en 2 subconjuntos. Sin pre procesamiento de datos iniciales Estimación anual error del 16%	Exógenos
[50] [51]	Considera coeficientes que relaciona numéricamente la energía incidente y la localización geográfica. Se amplía el modelo de Angstrom. Tiene en cuenta la altitud de la localidad.	Comportamiento constante lineal. Modelo Tierra-Sol, depende mucho de ángulos astronómicos de difícil cálculo	Endógeno
[52][53]	Tiene en consideración el efecto de las nubes en el desarrollo del modelo. Investiga la frecuencia de nubosidad en el cielo.	Modelo subestima valores en invierno y los sobreestima en verano. Basado en 22 modelos de banda óptica lo que genera ruido en el modelo total. Modela una región 3D que lo hace computacionalmente demandante.	Endógeno
[54] [55]	Evaluación de flujo global de Sol, frecuencia de distribución de radiación local. Muestra la variación estacional del recurso solar. Permite modelar la probabilidad anual para estaciones.	Modelo solo aplicado localmente. Coeficientes de relación calculados para la misma ciudad de prueba	Endógeno
[21] [22], [23]	Busca correlaciones entre datos no considerados en modelos anteriores. Considera las nubes como datos que influyen con su movimiento en la radiación incidente. Comienzo de modelos híbridos para predicción. R=0.96	Con grandes capas de nubes la precisión del modelo decrece. Modelo que depende 100% de la localización.	Exógenos
[43][56]–[59]	Explora correlaciones entre días. Introduce la nubosidad como parámetro de entrada. Etapas de pre y post procesamiento de resultados.	Computacionalmente demandante. En horizontes < 1h se presenta un error mayor. Mejorar precisión al mejorar píxeles de resolución de imagen.	Exógenos

III. PREDICCIÓN DE RADIACIÓN SOLAR

El Aprendizaje Automático, es un subcampo de las ciencias de la computación y se clasifica como un método propio de la inteligencia artificial IA. Este se usa en muchos dominios y campos, entre los que destaca: energético, económico y biológico. La ventaja de este método es la generación de un modelo que puede "tomar" decisiones que serían difíciles de ser representadas por algoritmos explícitos, como las aproximaciones numéricas y analíticas simples. Según [63] los modelos de Aprendizaje Automático encuentran relaciones entre entradas y salidas siempre que la representación sea posible.

Los modelos de Aprendizaje Automático para predicción de recurso primario pueden dividirse en 2 grandes categorías: aprendizaje supervisado y aprendizaje no supervisado. El aprendizaje supervisado es útil en los casos en que una propiedad (etiqueta) está disponible para un determinado conjunto de datos (conjunto de entrenamiento), pero falta y necesita ser predicho para otras instancias. Hacen parte del aprendizaje supervisado [64]:

- Árboles de decisión
- Máquinas de vectores de soporte (Clasificación).
- Vecinos.
- Lógica difusa.

El aprendizaje sin supervisión es útil en los casos en que el desafío consiste en descubrir relaciones implícitas en un conjunto de datos no etiquetado (los elementos no están asignados previamente). Hacen parte del aprendizaje no supervisado:

- Proceso Markov
- Máquinas de vectores de soporte (Predicción)
- Redes Neuronales.

En Aprendizaje Automático existen 3 etapas: la primera una etapa de preprocesamiento y clasificación de datos, la segunda la entrada de datos y la última etapa está dada por el tratamiento del error entre el dato estimado y el dato medido.

Además, para aplicar un modelo de Aprendizaje Automático

se debe tener en cuenta criterios como: tratamiento de la no-linealidad, comportamiento al usar múltiples entradas, horizonte de predicción, tratamiento del error asociado a la predicción. Estos son elementos que diferencian las técnicas de Aprendizaje Automático al ser aplicadas en predicción.

Estos criterios dan pautas en el desarrollo del modelo al tener en cuenta que el cálculo del error y habilidades de pronóstico de los modelos no dependen solo de las condiciones climáticas sino también del horizonte de predicción. Estos procesos, enmarcan la aplicación del modelo de predicción en una región en particular.

Para aplicaciones en predicción de radiación solar, el uso de Aprendizaje Automático fue evolutivo. Las primeras técnicas fueron las Redes Neuronales, su concepto y uso se ampliará más adelante y se trataban en su momento como parte de la IA. En trabajos anteriores a [65], [66], no se utilizaba una etapa de preprocesamiento a la entrada del modelo NN. A partir de estos trabajos se encuentra una correlación de entrada entre datos climáticos y la radiación. Este proceso es una primera aproximación para seleccionar datos climáticos de entrada más adecuados al modelo a desarrollar. En la Fig. 2 se muestra la evolución temporal de las técnicas utilizadas en predicción y estimación de radiación solar.

Según [67] existen conceptos propios de NN e IA que fueron heredados tiempo después por el Aprendizaje Automático. El término Aprendizaje Automático propiamente dicho para predicción de radiación solar, no aparece en la literatura sino hasta 2011 donde, en una primera aproximación se habla del aprendizaje desde los datos de entrada [68]. En este trabajo se desarrolla un algoritmo NN con entradas seleccionadas mediante técnicas que establecen relaciones entre los datos de la entrada y la salida.

En Aprendizaje Automático, se clasifica el modelo según el número de técnicas usadas. Si se usa una sola técnica desde la entrada de datos hasta la etapa final, normalmente sin preprocesamiento, se denomina *modelo unitario*. Si se usan dos o más técnicas por etapa, con procesamiento de datos presente, se denomina *modelo híbrido*.

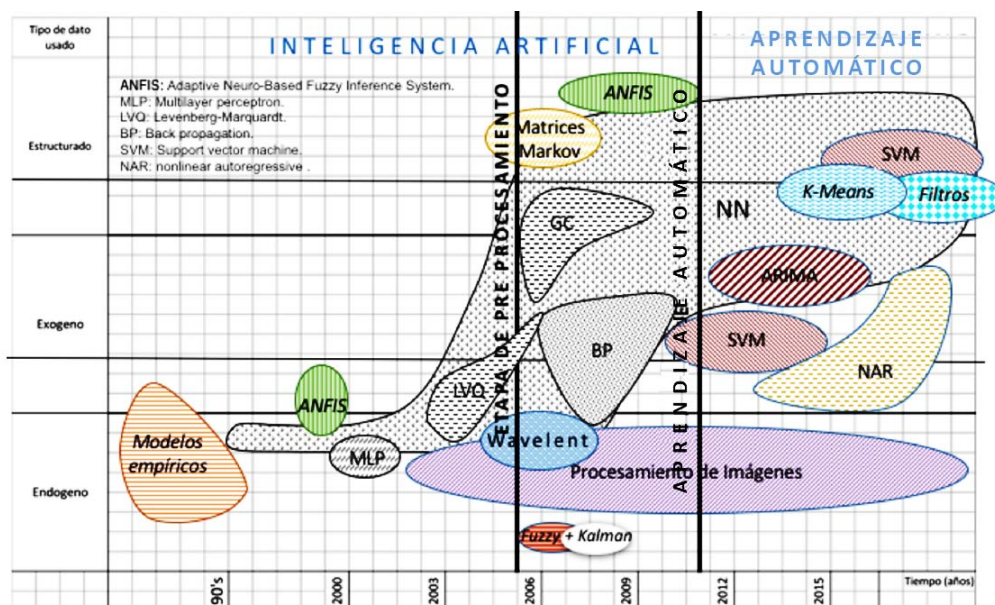


Fig. 2. Evolución temporal del uso de técnicas para predicción y estimación de radiación solar. Fuente: Propia.

A continuación, se presentan diferentes modelos de Aprendizaje Automático unitarios que se usaron en predicción. Los desafíos a los que se enfrentaron los autores y los avances que mostraron.

#### A. Procesos Markov

Un proceso de Markov es un proceso estocástico con propiedades Markov, lo que significa que, dado el estado actual, los estados futuros son independientes de los estados anteriores. Es decir, la descripción del estado actual captura toda la información que podría cambiar la evaluación de la función de valores futuros.

En trabajos como [9], [69] los valores predichos se alcanzan a través de un proceso probabilístico en lugar de uno determinista. En esta aproximación los datos de radiación se convierten a un número cuantificado entero de estados. Luego, pasan por una etapa de entrenamiento que forma los valores de probabilidad, finalmente pasan por pruebas de parámetros ocultos. Las pruebas se repitan para varios estados que dependen del número de predictores probabilísticos que se desarrollan en cada etapa. La ventaja de estos algoritmos es considerar las secuencias de eventos de entrada y construir dependencias transitorias entre el dato a predecir y el *dataset* de entrada. Sin embargo, hay una falta del conteo global para modelar y requiere una suposición inicial para generar las distribuciones, si no se estiman con una etapa de pre procesamiento optima puede dar lugar a errores.

#### B. Lógica Difusa (Fuzzy Logic).

El concepto de lógica difusa proporciona una forma natural de tratar problemas en los que la fuente de la imprecisión es la ausencia de criterios claramente definidos en lugar de la presencia de variables aleatorias. Para lograr esto se debe en primer momento, declarar las reglas de conjunto donde varias posibilidades de que suceda un evento. Estas reglas se relacionan mediante proposiciones difusas es decir oraciones del tipo, si-entonces, que se usan para caracterizar el estado de un sistema y el valor de verdad de la proposición se mide en relación a la coincidencia con el estado del sistema [15].

En lógica difusa, para la predicción de radiación solar, lo primero que se hace es elegir el número de variables de entrada. Las variables de entrada y salida pertenecen al mismo conjunto de datos. Es por eso que en las primeras aplicaciones [21], [28], [69]–[71] se usó como una etapa de pre procesamiento a la entrada. Debido a su gran precisión en la generación de las funciones de membresía en estos trabajos se muestra la clasificación en días: soleado, soleado-nuboso, nuboso, nuboso-lluvia, soleado-lluvia, entre otros. Los datos para poder clasificar los días en estos escenarios se caracterizan por los mismos atributos en *timestep* y las mismas funciones de pertenencia.

En otros trabajos como [72][73] se desarrollan modelos basados en Lógica Difusa. En varias etapas como cálculo del componente de cielo abierto, y luego caracterización, del día, que se basa en una correlación entre variables climáticas de entrada logran por medio de reglas preestablecidas generar el modelo total.

El error en estos trabajos respecto de NN es mayor en

aproximadamente un 5%. Trabajos como [74], [75] ha comparado esta técnica con otros algoritmos. Se muestra resultados aceptables cuyo desempeño es mayor. Sin embargo, en estos trabajos utilizan etapas de Lógica Difusa con hibridación de otros algoritmos.

#### C. Árboles de decisión (Decision tree).

El modelo de árboles de decisión comprende una serie de decisiones lógicas, similares a un diagrama de flujo, con nodos de decisión que indican que se debe tomar una decisión sobre un atributo. Estas se dividen en ramas de indican los resultados de tomar la decisión.

El árbol se termina con nodos de hojas (también conocidos como nodos terminales) que denotan el resultado de seguir una combinación de decisiones [64].

Se usa en trabajos como [76]. La idea básica en este algoritmo es muy simple. Se debe pronosticar una respuesta y a partir de las entradas  $x_1, x_2, \dots, x_p$ . Para esto se diseña un árbol binario. En cada nodo del árbol se aplica una prueba a la entrada comparándola con un valor determinado. Con este resultado se decide entre la subdivisión izquierda o derecha. Este algoritmo es muy dependiente de los horizontes de predicción, los datos a la entrada y varia los resultados entre uno y otro árbol. Sin embargo, se resalta su capacidad de procesamiento de datos en la entrada, su interpretación y análisis.

#### D. Máquinas de Vectores de Soporte (Support Vector Machine SVM.)

Usada en sus orígenes para solucionar problemas de clasificación, hoy en día son aplicadas a problemas de regresión y reconocimiento de patrones. La predicción calculada mediante una máquina de tipo SVM está dada como lo muestra la Ecuación 1:

$$\hat{y} = \sum_{i=1}^n \alpha_i k(x_i, x_*) + b \quad (1)$$

Donde  $x_*$  es una entrada de prueba.  $k$  es una función de activación definida mediante un proceso de concatenación de vectores en el espacio de trabajo a fin de generar el hiperplano de separación [64], [77].

El parámetro  $b$  o parámetro independiente se deriva de condiciones específicas, además de la incertidumbre asociada con la estimación. En el caso de SVM los coeficientes de aprendizaje  $\alpha_i$ , están relacionados con la solución de problemas de programación cuadrática.

El punto fuerte de este algoritmo, según [78] es su capacidad de resolución de problemas de alta complejidad y alta no-linealidad. Trabaja sobre regresión lineal múltiple y usa un transformador predictivo de baja complejidad con filtrado de datos.

En trabajos como [79]–[81], se utiliza el algoritmo SVM como técnica de estimación de radiación solar. En el primero de estos se introduce el concepto de Aprendizaje Automático en trabajos de este tipo. Si se compara SVM con modelos numéricos se encuentra que la incertidumbre asociada al valor estimado disminuye cerca de un 35% con el uso de SVM. Al ser un algoritmo que aprende de los datos depende directamente del pre procesamiento, lo que traduce en un desempeño aceptable pero que es computacionalmente demandante. En

estos trabajos se muestra que este tipo de algoritmo es muy dependiente de la función de activación usada, lo que hace difícil comparar su desempeño entre ellos.

#### E. *K-Vecinos Cercanos (K-Nearest Neighbors Knn)*.

El modelo comienza con un conjunto de datos de entrenamiento compuesto de ejemplos que se clasifican en varias categorías, como lo indica la variable nominal. Si a la entrada del modelo se tiene nuevos datos no etiquetados, para cada registro en el conjunto de datos de prueba. vecinos identifica  $k$  registros en los datos de entrenamiento que tienen la similitud "más cercana" donde  $k$  es un número entero especificado de antemano. A la instancia de prueba sin etiqueta se le asigna la clase de la mayoría de los  $k$  vecinos más cercanos [64].

Esta técnica está basada en un algoritmo de reconocimiento de patrones el cual compara el estado original con las muestras entrenadas. Según [31] este modelo predefine las vecindades más próximas al dato que se busca. Este tipo de modelo es usado en casos donde se tiene un número de días con radiación y perfil similar.

En [82] el horizonte de predicción comprende desde 5 hasta 30 min. a futuro y los correspondientes intervalos de incertidumbre. Un algoritmo de optimización determina el número de vecinos más cercanos. Los resultados de este trabajo muestran que los cambios abruptos en el *dataset* de entrada no se capturan de forma eficiente por pronósticos puntuales, esto principalmente porque esos eventos están subrepresentados, por faltantes en la medida, en el conjunto de entrada, lo que genera que el cálculo del vecino más cercano no sea el correcto.

#### F. *K-Medias (K-Means)*.

El modelo  $k$ -medias asigna cada uno de los  $n$  ejemplos a uno de los grupos  $k$ , donde  $k$  es un número que se ha definido antes de tiempo. El objetivo es minimizar las diferencias dentro de cada grupo y maximizar las diferencias entre los grupos. Es un modelo heurístico que encuentra soluciones óptimas a nivel local [64].

Es un método de cuantificación de vectores de asignación. Esta técnica usada en [46], [83], [84] divide las observaciones de entrada de radiación en clústeres en los que cada observación pertenece al clúster con la media más cercana, que sirve como prototipo de clúster. Resalta la diversidad de respuesta al poder procesar datos lineales y no lineales a la entrada. En estos trabajos se encuentran patrones de similitud entre la salida y la entrada. Además, no están presentes datos climáticos diferentes a radiación. Con el uso de diferentes técnicas (distancia euclidiana, método de inserción mínima) se encuentra el valor vecino más óptimo para clasificación.

#### G. *Redes Neuronales (Neural Networks NN)*.

Una red neuronal artificial (ANN) modela la relación entre un conjunto de señales de entrada y una señal de salida utilizando un modelo derivado de nuestra comprensión de cómo un cerebro biológico responde a los estímulos de las entradas sensoriales. Así como un cerebro usa una red de células interconectadas llamadas neuronas para crear un procesador paralelo masivo, la ANN utiliza una red de neuronas o nodos artificiales para resolver problemas de aprendizaje [64].

Las NN pueden aprender de los patrones de información dentro de un conjunto de datos. Son tolerantes a errores debido a la falta de datos en la entrada, una característica frecuente con los datos de recurso primario: viento y radiación solar [17], [85].

En [6] se hace una revisión de aplicación de NN en el campo energético, aplicaciones en la construcción de sistemas térmicos, predicción de demanda y tarificación de usuarios de energía eléctrica, hasta la predicción de recurso primario.

Las NN fueron las primeras técnicas que se implementaron para predecir los eventos asociados a aproximar variabilidad en recursos primarios de generación de energía [6], [86], [87]. Esto se debe a que el algoritmo NN es capaz de capturar de manera confiable la naturaleza no lineal de la radiación solar. Según [31] alrededor del 79% de las técnicas usadas en predicción de radiación se basan en un enfoque de conexiones con red neuronal. Aproximadamente el 20% restante se utilizan técnicas derivadas de redes neuronales tales como lógica difusa, *wavelength*, *Radial Basis Function RBFNN*.

Una reseña de la utilización de este tipo de técnicas se presenta en trabajos [29], [30], [66], [68], [80], [85], [87]–[111]. En estos trabajos se distinguen dos tipos de estudios: modelado con multicapas MLP (*Multilayer perceptron*), y predicción con series temporales. De hecho, MLP se utiliza con mucha más regularidad que otros algoritmos por su propiedad de "aproximación universal" capaz de desarrollar predicción no lineal. Además, existen trabajos que utilizan diferentes algoritmos en la etapa de entrenamiento del modelo, *Back Propagation BP*, gradiente descendente, Levenberg-Marquardt, *LVQ*, [112]–[114]. En la etapa oculta, característica de este modelo, el número de neuronas, por lo general, es determinado a partir de ensayo/error, por lo que difiere significativamente entre uno y otro trabajo. Sin embargo, se encuentra que a mayor número de neuronas en las etapas anteriores a la predicción el error disminuye. En [115] se desarrolla un modelo ANFIS entrenado por MLP (*Multilayer Perceptron*) cuya principal ventaja es modelar radiación con coordenadas geográficas, la cual hace las veces de entrada al modelo. El desempeño según los autores es superior si se usa RBFN y Redes neuronales de regresión (RNN), en gran parte a la combinación del MLP en la etapa de entrenamiento que pondera y calcula la mejor combinación de entrada. Luego por el algoritmo de Lógica Difusa se clasifica y finalmente se da una respuesta.

Los primeros trabajos se realizan entre 1998-1999. En [16], [17] usan un modelo NN con algoritmo *BP* en la etapa de entrenamiento. Los autores encuentran correlaciones entre datos climáticos (presión atmosférica) y radiación solar. En una primera aproximación se clasifica la radiación en alto, medio y bajo, que será una constante en los trabajos subsiguientes. Los resultados en predicción muestran un error entre el 18% en verano y 21% en invierno.

#### H. *Discusión*.

En los trabajos que usan NN [29], [30], [66], [68], [80], [85], [87]–[111], el error asociado a la predicción, con horizontes variables: intra-horario, intra-diario, hora siguiente y día siguiente están entre 7% y 15%. Se muestra una variación entre estudios debido a que algunos usan etapas de pre procesamiento

lo que hace que el error disminuya, además que se debe tener en consideración la baja precisión producida al considerar la variación estacional.

La Tabla II muestra los resultados de modelos Aprendizaje Automático unitarios usados en predicción de radiación solar y en la Fig. 3 se muestra la cantidad de trabajos publicados que usan modelos de Aprendizaje Automático para predicción de radiación solar. Para obtener esta figura se identificaron los

trabajos desde 1990 que hacen uso de modelos de aprendizaje automático en bases de datos como ScienceDirect e IEEE. Se identifica el modelo que usan los autores para predicción de radiación solar y se hace un compendio por año y por técnica de la cantidad de trabajos afines que se escribieron en ese periodo de tiempo, la búsqueda se hace por medio de palabras clave en cada año.

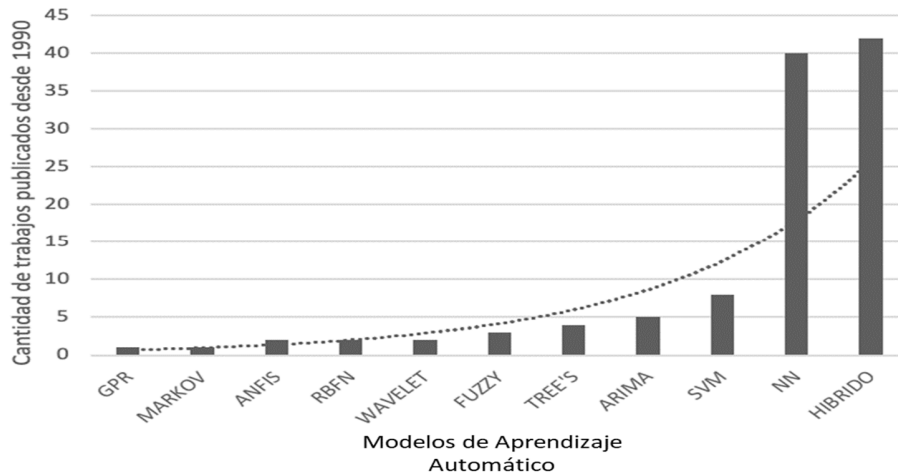


Fig. 3. Tendencia en número de trabajos publicados que hacen uso de técnicas ML en predicción y estimación de radiación solar. Fuente: Propia.

TABLA II  
LISTA DE TRABAJOS REPRESENTATIVOS RELACIONADOS CON PREDICCIÓN DE RADIACIÓN DONDE USAN ALGORITMOS ML SIMPLES. FUENTE: PROPIA

Referencia	Criterio de evaluación	Tipo de datos de entrada	Resultado
[27]	RMSE	Exógeno	NN>AR>GP>SVR>SC>Persistencia>Pers
[28]	RMSE	Exógenos	SVR RBFN>SVR poly>>Fuzzy Linear Regression
[66]	RMSE/MBE	Estructurado	NN> modelos de regresión lineal
[79]	rRMSE	Exógeno	SVM>modelos basados en temperatura
[9]	RMSE/MBE/MAPE	Exógeno	MLPNN>HMM-10>RBFNN
[84]	RMSE	Endógeno	k-means>LR
[70]	RMSE/MBE	Endógeno	NN>NWP
[72]	RMSE/MBE	Endógeno	Fuzzy>Regresión Lineal >NWP
[74]	RMSE-R	Estructurados	Fuzzy Genetic>ANN>ANFIS
[44]	RMSE	Endógeno	NN>Regresión lineal > ARIMA
[45]	MBE/RMSE	Endógeno	ARIMA> función GH <sub>i</sub>
[47]	MBE/RMSE	Exógenos	ARMA eq MLP > Bayesian>Markov
[109]	MAE	Endógeno	BP-M>LVQ-U>LM-M>ARIMA>NWP.
[87]	RMSE	Estructurado	RBFN>ML
[90]	MAPE	Exógenos	ANN>Angstrom
[93]	rRMSE	Endógeno	NN>ANFIS>AR>CI
[94]	RMSE	Endógeno	NN>AR>Markov>Neighbor
[116]	RMSE	Endógeno	EML>SVM>KNN>Persistencia
[117]	RMSE	Exógeno	GPR>ELM>SVM
[118]	RMSE	Endógeno	NN>ARMA>ARMA(Box Jenkins)
[8]	FANOVA	Endógeno	Modelo propuesto>NAM>SREF
[119]	RMSE -R	Estructurado	SVM>HMM>Sky image
[120]	RMSE-R	Estructurado/Endógeno	NN(BP)>ANN(Bayesian)
[121]	R	Estructurado	SVRPSO>SVRGA>SVR
[122]	RMSE	Exógeno.	GRNN>NARX>MLP>ANFIS



La tendencia indica que a un mediano y corto plazo ya no es común trabajar con un predictor unitario, si no con un modelo híbrido. Estos son diseñados mediante la combinación de dos o más técnicas con atributos superiores y aprovecha potencialidades individuales. Estas potencialidades se ven reflejadas en las etapas de Aprendizaje Automático. Cada etapa tiene combinación de dos o más técnicas, esto traduce en una mejor precisión (alrededor del 40%) en el modelo. Al comparar el resultado que entregan los modelos unitarios con el entregado por modelos híbridos el rendimiento de estas últimas es superior [31].

#### IV. MODELOS HÍBRIDOS

Uno de los primeros trabajos que desarrollaron modelos híbridos fue [65]. Este modelo consta de dos etapas: la primera usa NN para predecir valores de radiación solar mensual. La segunda etapa normaliza los valores de radiación los cuales hacen de entrada al modelo de matriz Transitoria de Markov. En estas matrices cada elemento representa la probabilidad de que el promedio diario de índice de claridad tenga dos valores particulares (que se encuentran dentro de intervalos particulares) de dos días consecutivos [123]. Se usan ampliamente para relacionar valores dados por funciones de probabilidad para cualquier periodo dado que pareciera tener una forma asociada con el promedio de datos en ese periodo [65], [123]. El error en este trabajo, [65], es cercano al 8% versus los modelos lineales y estadísticos con los que fue comparado. Este modelo es capaz de capturar el carácter no lineal de la radiación y ponderar probabilidades de suceso para encontrar el predictor.

En la Tabla III se muestra soluciones que combinan modelos de Aprendizaje Automático.

Se aprecia que, la técnica de hibridación da mejores resultados que usar predictores simples. Sin embargo, la mejor combinación de predictores para generación de un modelo de hibridación estándar no está definida. Se necesitan muchos más trabajos para proponer una metodología robusta que englobe todas las situaciones presentadas en el tratamiento de datos climáticos. Bajo el concepto híbrido de predicción se define una topología por etapas, como lo muestra la Fig. 4.

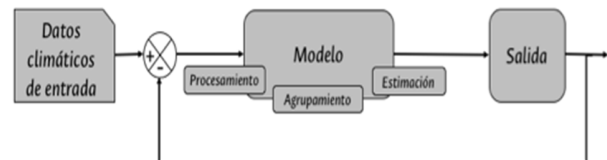


Fig. 4. Topología de predicción de radiación solar usando un modelo híbrido. Fuente: Propia.

Ejemplos de predicción bajo esta topología son [118], [132], [135]. En estos trabajos se tratan los datos de entrada como señales, las cuales deben pasar por tres procesos: el primero es el preprocesamiento, en esta etapa se definen los tipos y categorías de datos, su estructura y normalmente se usa técnicas asociadas para suplir el faltante de datos. El segundo es el de agrupamiento en el cual se definen perfiles de clima y tendencias de clasificación en los datos que conforman el clima, sea diario o mensual y finalmente la estimación, en este proceso se establecen relaciones entre entrada /salida a fin de encontrar la mejor relación que defina un perfil de recurso primario.

TABLA III  
LISTA DE TRABAJOS REPRESENTATIVOS RELACIONADOS CON PREDICCIÓN DE RADIACIÓN QUE USA MÉTODOS ML HÍBRIDOS. FUENTE: PROPIA

Referencia	Criterio de evaluación	Tipo de datos de entrada	Resultado
[42]	RMSE	Estructurados	CRO-ELM>ELM>SVM
[65]	RMSE	Estructurado	NN+MarkovMatrices>NN
[85]	RMSE	Estructurado	NN+SCG>NN+PR>
[71]	RMSE-MBE	Endógeno	DRWNN > CPR>BPnewtwork
[124]	RMSE	Exógeno	WNN+GAO>NN+LVQ
[125]	RMSE	Exógeno	WNN+PCA>NN(temporal)
[126]	nRMSE	Endógeno	Hibrido>TDNN>ARMA
[127]	MBE	Exógeno	ANN+MNLr>ANN(LVQ)
[128]	RMSE	Exógeno	WNN>ANN
[129]	Kolmogorov-Smirnov.	Endógeno	CARDS>NN>ARMA
[130]	RMSE	Endógeno	Propuesto>MLP>NN
[131]	RMSE	Exógenos	Propuesto >SOM>Kmeans>NG
[132]	RMSE	Estructurado	GSO-SVM-HARD>SVM-HARD
[133]	R	Estructurado.	BS-SVM>SVM> modelo local
[134]	RMSE/MBE	Estructurado	SVR+GBR+RFR>individuales>NWP
[135]	R	Estructurado	Wavelent+SVM>SVM
[136]	RMSE	Endógeno	K-means transformado>SOM> k means_var
[137]	RMSE/R	Endógeno	Mycielski- Markov>Mycielski method>ANN>ARIMA
[138]	RMSE	Estructurado	ANN/SA>ANN>GP>SVM
[139]	RMSE	Endógeno	SHBM>modelos basados en regresión lineal
[140]	RMSE/R	Exógeno	RF>ANN-RF>ANN>RF>RF-FFA

Además, existe realimentación, puesto que se debe comparar la estimación de salida con datos de entrada y estimar el error, a fin de determinar el desempeño del modelo.

Cada etapa, excepto los datos de entrada, está constituida por 2 o más predictores unitarios. Es así como en [141] y [138] se usan predictores unitarios a la entrada de los datos y en el agrupamiento. En el primer trabajo se usa NN como *kernel* de SVM lo que hace que el error del modelo sea menor (<2%) respecto a los modelos comparados. Mientras que en el segundo se usa SVM como criterio de comparación para generar un ciclo de retroalimentación en la entrada del modelo.

Cabe resaltar que no existen algoritmos predefinidos para cada etapa, pero es posible establecer una tendencia de uso. Así es como en el modelo para la etapa de preprocesamiento se usan k-NN, Lógica Difusa y árboles de decisión. En la etapa de agrupamiento y estimación NN y SVM [73], [108], [122], [140], [142].

V. PROPUESTA AL FUTURO

Son muchas las direcciones en las que los modelos de Aprendizaje Automático se pueden integrar. Entre las que destaca, la inserción de los modelos en aspectos de predicción a corto plazo: análisis y comparación de rendimiento del modelo al considerar diferentes bases de datos para comprobar su validez y la inserción en la planeación de estrategias computacionales en la toma de decisiones.

Se sugiere incluir en el modelo variables de tipo económico en base al recurso primario predicho. Para la variable económica el Costo Nivelado de Energía, (LCOE), es la herramienta sugerida para decidir si en base a su potencial energético una región geográfica determinada podría a largo plazo producir electricidad solar y diversificar la matriz eléctrica. En el aspecto del cálculo de energía en firme para cargos por confiabilidad el modelo podría ser una herramienta para insertar el comportamiento de la planta al tener en cuenta datos distintos a radiación y temperatura y así caracterizar el

país en regiones solares productivas, las cuales darán una idea de potencial y brindaran información del comportamiento del recurso primario [143].

La Fig. 5 sintetiza de mejor manera donde los modelos de Aprendizaje Automático se pueden integrar como herramientas de apoyo.

VI. CONCLUSIONES

En el presente trabajo se identifican y analizan técnicas para estimar y predecir radiación solar. Su desarrollo fue evolutivo con el paso del tiempo, desde las relaciones empíricas hasta llegar al Aprendizaje Automático.

La tendencia en los últimos años es desarrollar predictores híbridos más que unitarios, lo que permite estudiar el problema de la estimación de radiación, no como un concepto estocástico sino no como una suma de señales que deben ser analizadas en etapas y para cada etapa se debe seleccionar el algoritmo más adecuado. A la entrada el modelo debe ser capaz de capturar la no-linealidad de los datos de entrada, incluida radiación, para después generar la clasificación y agrupamiento correspondiente sin descuidar el incremento del error en estas dos etapas, para finalizar la estimación con una técnica que tenga en cuenta relaciones entre el dataset de entrada y la salida de radiación que se predice.

La respuesta a la pregunta de cuál o cuáles son los mejores algoritmos para predecir radiación, no es fácil de responder. Esto en gran parte a los pronósticos resultantes que difieren en muchos puntos geográficos. Así pues, para cada región en particular debe escoger el modelo más apropiado el cual debe seguir una tendencia de aplicación en regiones similares.

El proceso de desarrollo de un modelo de pronóstico pasa por la evaluación de ciertos criterios en los que está enmarcado el desempeño y comportamiento del modelo, ya sea híbrido o unitario. Estos criterios son los elementos de decisión primarios en el diseño de un modelo.

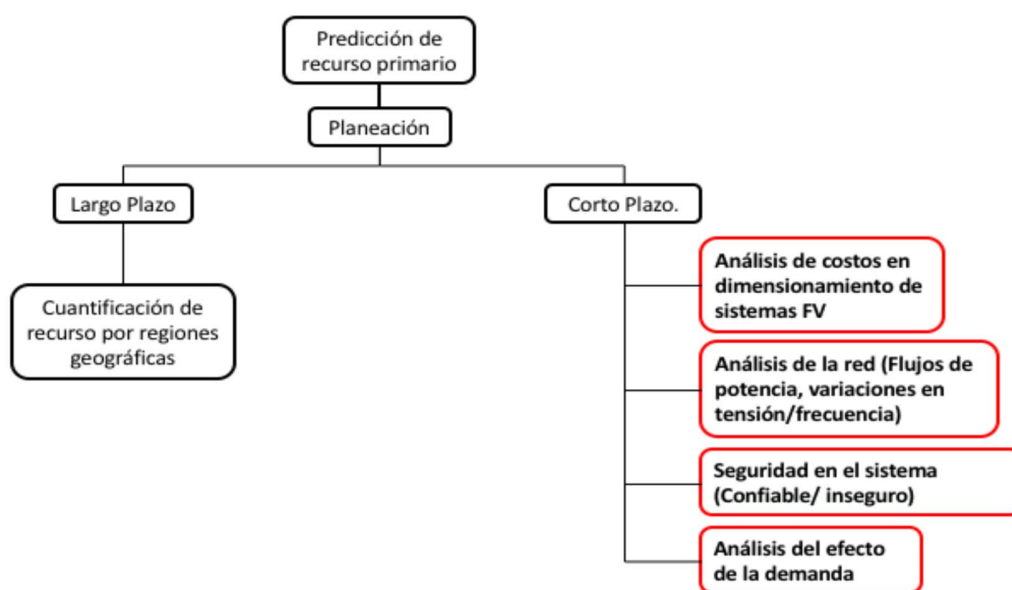


Fig. 5. Diagrama de flujo como sugerencia de trabajos futuros. Fuente: adaptado de [143].

El comportamiento no lineal de la radiación, lleva a pensar en un modelo de que sea capaz de responder a los cambios presentados en tiempos cortos y aumentar el tiempo de convergencia al valor determinado. Las diferentes localizaciones geográficas y por ende la radiación cambian el valor dado lo que genera una diferencia en la respuesta del modelo y el valor medido.

#### AGRADECIMIENTOS

Los autores desean agradecer el apoyo financiero de la DIMA (Dirección de Investigación Manizales) para la financiación de esta investigación a través de la aprobación del proyecto "Diseño de estrategias operativas para la integración eficiente de recursos de energía distribuida en las redes de distribución en Colombia", con sistema código Hermes 35911.

#### REFERENCIAS

- [1] I. Renewable and E. Agency, *Renewable Energy Statistics 2017 Statistiques D ' Énergie Renouvelable 2017 Estadísticas De Energía*. 2017.
- [2] E. Obando-Paredes and R. Vargas-Cañas, "Desempeño de un sistema fotovoltaico autónomo frente a condiciones medioambientales de una región en particular," *Rev. la Acad. Colomb. Ciencias Exactas, Físicas y Nat.*, vol. 40, no. 154, pp. 27–33, 2016.
- [3] R. J. Davy and A. Troccoli, "Interannual variability of solar energy generation in Australia," *Sol. Energy*, vol. 86, no. 12, pp. 3554–3560, 2012.
- [4] M. Mitchell, M. Campbell, K. Klement, and M. Sedighy, "Power variability analysis of megawatt-scale solar photovoltaic installations," *2016 IEEE Electr. Power Energy Conf. EPEC 2016*, pp. 1–4, 2016.
- [5] E. Ghiani, F. Pilo, and S. Cossu, "Evaluation of photovoltaic installations performances in Sardinia," *Energy Convers. Manag.*, vol. 76, pp. 1134–1142, 2013.
- [6] S. a Kalogirou, "Artificial neural networks in renewable energy systems applications: a review," *Renew. Sustain. Energy Rev.*, vol. 5, no. 4, pp. 373–401, 2001.
- [7] T. Khatib, A. Mohamed, and K. Sopian, "A review of solar energy modeling techniques," *Renew. Sustain. Energy Rev.*, vol. 16, no. 5, pp. 2864–2869, 2012.
- [8] X. Shao, S. Lu, and H. F. Hamann, "Solar radiation forecast with machine learning," *Proc. AM-FPD 2016 - 23rd Int. Work. Act. Flatpanel Displays Devices TFT Technol. FPD Mater.*, pp. 19–22, 2016.
- [9] F. O. Hocaoglu, "Stochastic approach for daily solar radiation modeling," *Sol. Energy*, vol. 85, no. 2, pp. 278–287, 2011.
- [10] E. Cadenas, W. Rivera, R. Campos-Amezcuca, and R. Cadenas, "Wind speed forecasting using the NARX model, case: La Mata, Oaxaca, México," *Neural Comput. Appl.*, vol. 27, no. 8, pp. 2417–2428, 2016.
- [11] L. M. López-Manrique, E. V. Macias-Melo, O. M. Tzuc, A. Bassam, K. M. Aguilar-Castro, and I. Hernández-Pérez, "Assessment of resource and forecast modeling of wind speed through an evolutionary programming approach for the north of tehuantepec isthmus (Cuauhtemotzin, Mexico)," *Energies*, vol. 11, no. 11, pp. 1–22, 2018.
- [12] B. Laarabi, O. May Tzuc, D. Dahlioui, A. Bassam, M. Flota-Bañuelos, and A. Barhdadi, "Artificial neural network modeling and sensitivity analysis for soiling effects on photovoltaic panels in Morocco," *Superlattices Microstruct.*, vol. 127, no. 2017, pp. 139–150, 2019.
- [13] O. May Tzuc, A. Bassam, P. E. Mendez-Monroy, and I. S. Dominguez, "Estimation of the operating temperature of photovoltaic modules using artificial intelligence techniques and global sensitivity analysis: A comparative approach," *J. Renew. Sustain. Energy*, vol. 10, no. 3, 2018.
- [14] G. A. Tshirintzis, M. Virvou, and L. C. Jain, "Deep Learning for Photovoltaic Power Plant Forecasting," vol. 1, pp. 1–4, 2016.
- [15] E. Group, "FUZZY ALGORITHM FOR ESTIMATION OF SOLAR IRRADIATION," vol. 63, no. 1, pp. 39–49, 1998.
- [16] Y. Kemmoku, S. Orita, S. Nakagawa, and T. Sakakibara, "Daily insolation forecasting using a multi-stage neural network," *Sol. Energy*, vol. 66, no. 3, pp. 193–199, 1999.
- [17] and T. O. H. M. Mohandes, S. Rehman, "Estimation of Global Solar Radiation Using Artificial Neural Networks in Abu Dhabi City, United Arab Emirates," *J. Sol. Energy Eng.*, 1998.
- [18] R. Perez *et al.*, "Comparison of numerical weather prediction solar irradiance forecasts in the US, Canada and Europe," *Sol. Energy*, vol. 94, pp. 305–326, 2013.
- [19] F. Díaz, G. Montero, J. M. Escobar, E. Rodríguez, and R. Montenegro, "An adaptive solar radiation numerical model," *J. Comput. Appl. Math.*, vol. 236, no. 18, pp. 4611–4622, 2012.
- [20] F. Díaz, G. Montero, J. M. Escobar, E. Rodríguez, and R. Montenegro, "A new predictive solar radiation numerical model," *Appl. Math. Comput.*, vol. 267, pp. 596–603, 2015.
- [21] C. L. Fu and H. Y. Cheng, "Predicting solar irradiance with all-sky image features via regression," *Sol. Energy*, vol. 97, pp. 537–550, 2013.
- [22] R. Marquez and C. F. M. Coimbra, "Intra-hour DNI forecasting based on cloud tracking image analysis," *Sol. Energy*, vol. 91, pp. 327–336, 2013.
- [23] Z. Peng, D. Yu, D. Huang, J. Heiser, S. Yoo, and P. Kalb, "3D cloud detection and tracking system for solar forecast using multiple sky imagers," *Sol. Energy*, vol. 118, pp. 496–519, 2015.
- [24] X. Zhang, "A statistical approach for sub-hourly solar radiation reconstruction," *Renew. Energy*, vol. 71, pp. 307–314, 2014.
- [25] G. Oturanc, A. Hepbasli, and A. Genc, "Statistical Analysis of Solar Radiation Data," no. January 2013, pp. 37–41.
- [26] A. Peled and J. Appelbaum, "Evaluation of solar radiation properties by statistical tools and wavelet analysis," *Renew. Energy*, vol. 59, pp. 30–38, 2013.
- [27] P. Lauret, C. Voyant, T. Soubdhan, M. David, and P. Poggi, "A benchmarking of machine learning techniques for solar radiation forecasting in an insular context," *Sol. Energy*, vol. 112, p. 0, 2015.
- [28] Z. Ramedani, M. Omid, A. Keyhani, and B. Khoshnevisan, "A comparative study between fuzzy linear regression and support vector regression for global solar radiation prediction in Iran," *Sol. Energy*, vol. 109, pp. 135–143, 2014.
- [29] A. Alzahrani, P. Shamsi, C. Dagli, and M. Ferdowsi, "Solar Irradiance Forecasting Using Deep Neural Networks," *Procedia Comput. Sci.*, vol. 114, pp. 304–313, 2017.
- [30] A. Mellit and A. Massi, "A 24-h forecast of solar irradiance using artificial neural network : Application for performance prediction of a grid-connected PV plant at Trieste , Italy," *Sol. Energy*, vol. 84, no. 5, pp. 807–821, 2010.
- [31] C. Voyant *et al.*, "Machine learning methods for solar radiation forecasting: A review," *Renewable Energy*, vol. 105. Elsevier Ltd, pp. 569–582, 2017.
- [32] M. R. Rietveld, "A NEW METHOD FOR ESTIMATING THE REGRESSION COEFFICIENTS IN THE FORMULA RELATING SOLAR RADIATION TO SUNSHINE M," vol. 19, pp. 243–252, 1978.
- [33] A. Angstrom, "Solar and terrestrial radiation," *Rep. to Int. Com. Sol. Res. actiometric Investig. Sol. Atmos. Radiat.*, pp. 135–138, 1924.
- [34] R. A. and M. COLLARES-PEREIRA, "A TIME-DEPENDENT , AUTOREGRESSIVE , GAUSSIAN MODEL FOR GENERATING SYNTHETIC HOURLY RADIATION," vol. 49, pp. 167–174, 1992.
- [35] R. D. LEMOINE, "CLASSIFICATION OF RADIATION SITES IN TERMS," pp. 94–107, 1983.
- [36] K. G. Krishnan, K. Schöller, and E. Uhl, "Application of a Compact High-Definition Exoscope for Illumination and Magnification in High-Precision Surgical Procedures," *World Neurosurg.*, vol. 97, no. 026, pp. 652–660, 2017.
- [37] R. Chen, E. Kang, X. Ji, J. Yang, and J. Wang, "An hourly solar radiation model under actual weather and terrain conditions : A case study in Heihe river basin," vol. 32, pp. 1148–1157, 2007.
- [38] K. K. Gopinathan, "A new model for estimating total solar radiation," vol. 5, no. L, pp. 107–109, 1988.
- [39] F. J. Newland, "A STUDY OF SOLAR RADIATION MODELS FOR THE COASTAL REGION OF SOUTH CHINA," vol. 43, no. 4, pp. 227–235, 1989.
- [40] C. Mustacchi, V. Cena, M. Rocchi, C. Applicata, U. Roma, and R. Italia, "STOCHASTIC SIMULATION OF HOURLY GLOBAL RADIATION SEQUENCES," vol. 23, no. 2, pp. 47–51, 1979.
- [41] P. K. Pandey and M. L. Soupir, "A new method to estimate average hourly global solar radiation on the horizontal surface," *Atmos. Res.*, vol. 114–115, pp. 83–90, 2012.
- [42] S. Salcedo-Sanz, C. Casanova-Mateo, A. Pastor-Sánchez, and M. Sánchez-Girón, "Daily global solar radiation prediction based on a hybrid Coral Reefs Optimization - Extreme Learning Machine approach," *Sol. Energy*, vol. 105, pp. 91–98, 2014.
- [43] F. O. Hocaoglu, Ö. N. Gerek, and M. Kurban, "Hourly solar radiation forecasting using optimal coefficient 2-D linear filters and feed-forward

- neural networks," *Sol. Energy*, vol. 82, no. 8, pp. 714–726, 2008.
- [44] G. Reikard, "Predicting solar radiation at high resolutions: A comparison of time series forecasts," *Sol. Energy*, vol. 83, no. 3, pp. 342–349, 2009.
- [45] D. Yang, P. Jirutitjaroen, and W. M. Walsh, "Hourly solar irradiance time series forecasting using cloud cover index," *Sol. Energy*, vol. 86, no. 12, pp. 3531–3543, 2012.
- [46] J. Wu and C. K. Chan, "Prediction of hourly solar radiation with multi-model framework," *Energy Convers. Manag.*, vol. 76, pp. 347–355, 2013.
- [47] C. Voyant, C. Paoli, M. Muselli, and M. L. Nivet, "Multi-horizon solar radiation forecasting for Mediterranean locations using time series models," vol. 28, pp. 44–52, 2013.
- [48] M. David, F. Ramahatana, P. J. Trombe, and P. Lauret, "Probabilistic forecasting of the solar irradiance with recursive ARMA and GARCH models," *Sol. Energy*, vol. 133, pp. 55–72, 2016.
- [49] F. Nomiya, J. Asai, T. Murakami, H. Takano, and J. Murata, "A study on global solar radiation forecasting models using meteorological data and their application to wide area forecast," *2012 IEEE Int. Conf. Power Syst. Technol.*, pp. 1–6, 2012.
- [50] A. N. Syafawati et al., "Forecasting the potential of solar energy harvest in Kangar," *Proc. 2013 IEEE 7th Int. Power Eng. Optim. Conf. PEOCO 2013*, no. June, pp. 77–82, 2013.
- [51] S. A. Fatemi and A. Kuh, "Solar radiation forecasting using zenith angle," *2013 IEEE Glob. Conf. Signal Inf. Process. Glob. 2013 - Proc.*, pp. 523–526, 2013.
- [52] H. Ohtake, K. ichi Shimose, J. G. da S. Fonseca, T. Takashima, T. Oozeki, and Y. Yamada, "Accuracy of the solar irradiance forecasts of the japan meteorological agency mesoscale model for the kanto region, Japan," *Sol. Energy*, vol. 98, pp. 138–352, 2013.
- [53] Y. Liu, S. Shimada, J. Yoshino, T. Kobayashi, Y. Miwa, and K. Furuta, "Ensemble forecasting of solar irradiance by applying a mesoscale meteorological model," *Sol. Energy*, vol. 136, pp. 597–605, 2016.
- [54] A. Manzano, M. L. Martin, F. Valero, and C. Armenta, "A single method to estimate the daily global solar radiation from monthly data," *Atmos. Res.*, vol. 166, pp. 70–82, 2015.
- [55] A. Ridha et al., "Experimental assessment of the solar energy potential in the gulf of Tunis, Tunisia," *Renew. Sustain. Energy Rev.*, vol. 20, pp. 155–168, 2013.
- [56] R. Perez, S. Kivalov, J. Schlemmer, K. Hemker, D. Renné, and T. E. Hoff, "Validation of short and medium term operational solar radiation forecasts in the US," *Sol. Energy*, vol. 84, no. 12, pp. 2161–2172, 2010.
- [57] A. Moghaddam and A. R. Seifi, "Study of forecasting renewable energies in smart grids using linear predictive filters and neural networks," *IET Renew. Power Gener.*, vol. 5, no. 6, p. 470, 2011.
- [58] Y. Chu, H. T. C. Pedro, and C. F. M. Coimbra, "Hybrid intra-hour DNI forecasts with sky image processing enhanced by stochastic learning," *Sol. Energy*, vol. 98, no. PC, pp. 592–603, 2013.
- [59] L. F. Zarzalejo, L. Ramirez, and J. Polo, "Artificial intelligence techniques applied to hourly global irradiance estimation from satellite-derived cloud index," *Energy*, vol. 30, no. 9 SPEC. ISS., pp. 1685–1697, 2005.
- [60] R. Perez, K. Moore, S. Wilcox, D. Renné, and A. Zelenka, "Forecasting solar radiation - Preliminary evaluation of an approach based upon the national forecast database," *Sol. Energy*, vol. 81, no. 6, pp. 809–812, 2007.
- [61] F. Nomiya, J. Asai, T. Murakami, and J. Murata, "A study on global solar radiation forecasting using weather forecast data," *Circuits Syst. (MWSCAS), 2011 IEEE 54th Int. Midwest Symp.*, pp. 1–4, 2011.
- [62] Jan Kleissl, *Solar Energy Forecasting and Resource Assessment*. 2012.
- [63] C. M. Bishop, *Pattern Recognition and Machine Learning*, vol. 4, no. 4. 2006.
- [64] B. Lantz, *Machine Learning with R*. 2017.
- [65] A. Mellit, M. Benganem, A. H. Arab, and A. Guessoum, "A simplified model for generating sequences of global solar radiation data for isolated sites: Using artificial neural network and a library of Markov transition matrices approach," *Sol. Energy*, vol. 79, no. 5, pp. 469–482, 2005.
- [66] Y. Jiang, "Computation of monthly mean daily global solar radiation in China using artificial neural networks and comparison with other empirical models," *Energy*, vol. 34, no. 9, pp. 1276–1283, 2009.
- [67] A. Mellit, S. A. Kalogirou, L. Hontoria, and S. Shaari, "Artificial intelligence techniques for sizing photovoltaic systems: A review," *Renew. Sustain. Energy Rev.*, vol. 13, no. 2, pp. 406–419, 2009.
- [68] R. Marquez and C. F. M. Coimbra, "Forecasting of global and direct solar irradiance using stochastic learning methods, ground experiments and the NWS database," *Sol. Energy*, vol. 85, no. 5, pp. 746–756, 2011.
- [69] S. Bhardwaj et al., "Estimation of solar radiation using a combination of Hidden Markov Model and generalized Fuzzy model," *Sol. Energy*, vol. 93, pp. 43–54, 2013.
- [70] M. Chaabene and M. Ben Ammar, "Neuro-fuzzy dynamic model with Kalman filter to forecast irradiance and temperature for solar energy systems," *Renew. Energy*, vol. 33, no. 7, pp. 1435–1443, 2008.
- [71] J. C. Å and X. Lin, "Application of the diagonal recurrent wavelet neural network to solar irradiation forecast assisted with fuzzy technique," vol. 21, pp. 1255–1263, 2008.
- [72] R. S. Boata and P. Gravila, "Functional fuzzy approach for forecasting daily global solar irradiation," *Atmos. Res.*, vol. 112, pp. 79–88, 2012.
- [73] B. Sivaneasan, C. Y. Yu, and K. P. Goh, "Solar Forecasting using ANN with Fuzzy Logic Pre-processing," *Energy Procedia*, vol. 143, pp. 727–732, 2017.
- [74] O. Kisi, "Modeling solar radiation of Mediterranean region in Turkey by using fuzzy genetic approach," *Energy*, vol. 64, pp. 429–436, 2014.
- [75] F. Baser and H. Demirhan, "A fuzzy regression with support vector machine approach to the estimation of horizontal global solar radiation," *Energy*, vol. 123, pp. 229–240, 2017.
- [76] T. C. McCandless, S. E. Haupt, and G. S. Young, "A model tree approach to forecasting solar irradiance variability," *Sol. Energy*, vol. 120, pp. 514–524, 2015.
- [77] A. Karatzoglou, D. Meyer, and K. Hornik, "Support Vector Algorithm in R," *J. Stat. Softw.*, vol. 15, no. 9, pp. 1–28, 2006.
- [78] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. J. Martinez-de-Pison, and F. Antonanzas-Torres, "Review of photovoltaic power forecasting," *Sol. Energy*, vol. 136, pp. 78–111, 2016.
- [79] J. L. Chen, H. Bin Liu, W. Wu, and D. T. Xie, "Estimation of monthly solar radiation from measured temperatures using support vector machines - A case study," *Renew. Energy*, vol. 36, no. 1, pp. 413–420, 2011.
- [80] X. Yan, B. Francois, E. C. De Lille, C. Scientifique, and V. Asqc, "Solar Radiation Forecasting Using Artificial Neural Network for Local Power Reserve," pp. 2–7, 2014.
- [81] J. L. Chen, G. S. Li, and S. J. Wu, "Assessing the potential of support vector machine for estimating daily solar radiation using sunshine duration," *Energy Convers. Manag.*, vol. 75, pp. 311–318, 2013.
- [82] H. T. C. Pedro and C. F. M. Coimbra, "Nearest-neighbor methodology for prediction of intra-hour global horizontal and direct normal irradiances," *Renew. Energy*, vol. 80, pp. 770–782, 2015.
- [83] K. Benmouiza and A. Chekmane, "Forecasting hourly global solar radiation using hybrid k-means and nonlinear autoregressive neural network models," *Energy Convers. Manag.*, vol. 75, pp. 561–569, 2013.
- [84] M. Yesilbudak, I. Colak, and R. Bayindir, "K-means partition of monthly average insolation period data for Turkey," *Proc. - 2016 15th IEEE Int. Conf. Mach. Learn. Appl. ICMLA 2016*, pp. 436–440, 2017.
- [85] A. Sözen, E. Arcaklioğlu, M. Özalp, and N. Çağlar, "Forecasting based on neural network approach of solar potential in Turkey," *Renew. Energy*, vol. 30, no. 7, pp. 1075–1090, 2005.
- [86] and T. O. H. M. Mohandes, S. Rehman, Y. Kemmoku, S. Orita, S. Nakagawa, T. Sakakibara, and E. Group, "Estimation of Global Solar Radiation Using Artificial Neural Networks in Abu Dhabi City, United Arab Emirates," *J. Sol. Energy Eng.*, vol. 66, no. 3, pp. 193–199, 1998.
- [87] A. Dorvjo, J. Jervase, and A. Al-Lawati, "Solar radiation estimation using artificial neural networks," *Appl. Energy*, vol. 74, pp. 307–319, 2002.
- [88] H. K. Elminir, F. F. Areeed, and T. S. Elsayed, "Estimation of solar radiation components incident on Helwan site using neural networks," *Sol. Energy*, vol. 79, no. 3, pp. 270–279, 2005.
- [89] J. Mubiru and E. J. K. B. Banda, "Estimation of monthly average daily global solar irradiation using artificial neural networks," *Sol. Energy*, vol. 82, no. 2, pp. 181–187, 2008.
- [90] A. Azadeh, A. Maghsoudi, and S. Sohrabkhani, "An integrated artificial neural networks approach for predicting global radiation," *Energy Convers. Manag.*, vol. 50, no. 6, pp. 1497–1505, 2009.
- [91] M. Benganem, A. Mellit, and S. N. Alamri, "ANN-based modelling and estimation of daily global solar radiation data: A case study," *Energy Convers. Manag.*, vol. 50, no. 7, pp. 1644–1655, 2009.
- [92] D. A. Fadare, "Modelling of solar energy potential in Nigeria using an artificial neural network model," *Appl. Energy*, vol. 86, no. 9, pp. 1410–1422, 2009.
- [93] L. Martín, L. F. Zarzalejo, J. Polo, A. Navarro, R. Marchante, and M. Cony, "Prediction of global solar irradiance based on time series analysis: Application to solar thermal power plants energy production planning," *Sol. Energy*, vol. 84, no. 10, pp. 1772–1781, 2010.

- [94] C. Paoli, C. Voyant, M. Muselli, and M. L. Nivet, "Forecasting of preprocessed daily solar radiation time series using neural networks," *Sol. Energy*, vol. 84, no. 12, pp. 2146–2160, 2010.
- [95] A. Koca, H. F. Oztop, Y. Varol, and G. O. Koca, "Estimation of solar radiation using artificial neural networks with different input parameters for Mediterranean region of Anatolia in Turkey," *Expert Syst. Appl.*, vol. 38, no. 7, pp. 8756–8762, 2011.
- [96] A. Linares-Rodriguez, J. A. Ruiz-Arias, D. Pozo-Vázquez, and J. Tovar-Pescador, "Generation of synthetic daily global solar radiation data based on ERA-Interim reanalysis and artificial neural networks," *Energy*, vol. 36, no. 8, pp. 5356–5365, 2011.
- [97] C. Voyant, M. Muselli, C. Paoli, and M. L. Nivet, "Optimization of an artificial neural network dedicated to the multivariate forecasting of daily global radiation," *Energy*, vol. 36, no. 1, pp. 348–359, 2011.
- [98] N. Zhang and P. K. Behera, "Solar radiation prediction based on recurrent neural networks trained by Levenberg-Marquardt backpropagation learning algorithm," *2012 IEEE PES Innov. Smart Grid Technol. ISGT 2012*, 2012.
- [99] A. Ouammi, D. Zejli, H. Dagdougui, and R. Benchrifa, "Artificial neural network analysis of Moroccan solar potential," *Renew. Sustain. Energy Rev.*, vol. 16, no. 7, pp. 4876–4889, 2012.
- [100] A. Hasni, A. Sehli, B. Draoui, A. Bassou, and B. Amieur, "Estimating global solar radiation using artificial neural network and climate data in the south-western region of Algeria," *Energy Procedia*, vol. 18, pp. 531–537, 2012.
- [101] M. Rumbayan, A. Abudureyimu, and K. Nagasaka, "Mapping of solar energy potential in Indonesia using artificial neural network and geographical information system," *Renew. Sustain. Energy Rev.*, vol. 16, no. 3, pp. 1437–1449, 2012.
- [102] M. S. Islam, M. M. Kabir, and N. Kabir, "Artificial Neural Networks based Prediction of Insolation on Horizontal Surfaces for Bangladesh," *Procedia Technol.*, vol. 10, pp. 482–491, 2013.
- [103] A. N. Celik and T. Muneer, "Neural network based method for conversion of solar radiation data," *Energy Convers. Manag.*, vol. 67, pp. 117–124, 2013.
- [104] B. Amrouche and X. Le Pivert, "Artificial neural network based daily local forecasting for global solar radiation," *Appl. Energy*, vol. 130, pp. 333–341, 2014.
- [105] K. Kadirgama, A. K. Amirruddin, and R. A. Bakar, "Estimation of solar radiation by artificial networks: East coast Malaysia," *Energy Procedia*, vol. 52, pp. 383–388, 2014.
- [106] B. M. Alluhaidah, S. H. Shehadeh, and M. E. El-Hawary, "Most Influential Variables for Solar Radiation Forecasting Using Artificial Neural Networks," *2014 IEEE Electr. Power Energy Conf.*, pp. 71–75, 2014.
- [107] L. Ma, N. Yorino, and K. Khorasani, "Solar radiation (insolation) forecasting using constructive neural networks," *Proc. Int. Jt. Conf. Neural Networks*, vol. 2016–Octob, no. 3, pp. 4991–4998, 2016.
- [108] S. Çevik, "A Day Ahead Hourly Solar Radiation Forecasting by Artificial Neural Networks: A Case Study for Trabzon Province Yapay Sinir A  lar ˆ ile G ˆ un ˆ Oncesi Saatlik G ˆ une ˆ u Radyasyonu Tahmini: Trabzon ˆ li ˆ Orne ˆ i," 2017.
- [109] A. Sfetos and A. H. Coonick, "Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques," *Sol. Energy*, vol. 68, no. 2, pp. 169–178, 2000.
- [110] K. S. Reddy and M. Ranjan, "Solar resource estimation using artificial neural networks and comparison with other correlation models," *Energy Convers. Manag.*, vol. 44, no. 15, pp. 2519–2530, 2003.
- [111] L. Hontoria, J. Aguilera, and P. Zufiria, "Generation of hourly irradiation synthetic series using the neural network multilayer perceptron," *Sol. Energy*, vol. 72, no. 5, pp. 441–446, 2002.
- [112] S. Cao and J. Cao, "Forecast of solar irradiance using recurrent neural networks combined with wavelet analysis," *Appl. Therm. Eng.*, vol. 25, no. 2–3, pp. 161–172, 2005.
- [113] S. A. Fatemi and A. Kuh, "Solar radiation forecasting under asymmetric cost functions," *Proc. Int. Jt. Conf. Neural Networks*, pp. 1727–1732, 2014.
- [114] P. Melin, J. Amezcua, F. Valdez, and O. Castillo, "A new neural network model based on the LVQ algorithm for multi-class classification of arrhythmias," *Inf. Sci. (Ny)*, vol. 279, no. April, pp. 483–497, 2014.
- [115] A. Mellit, S. A. Kalogirou, S. Shaari, H. Salhi, and A. Hadj Arab, "Methodology for predicting sequences of mean monthly clearness index and daily solar radiation data in remote areas: Application for sizing a stand-alone PV system," *Renew. Energy*, vol. 33, no. 7, pp. 1570–1590, 2008.
- [116] S. Ferrari, M. Lazzaroni, V. Piuri, A. Salman, L. Cristaldi, and M. Faifer, "Computational intelligence models for solar radiation prediction," *Conf. Rec. - IEEE Instrum. Meas. Technol. Conf.*, pp. 757–762, 2013.
- [117] S. Salcedo-Sanz, C. Casanova-Mateo, J. Munoz-Mari, and G. Camps-Valls, "Prediction of Daily Global Solar Irradiation Using Temporal Gaussian Processes," *IEEE Geosci. Remote Sens. Lett.*, vol. 11, no. 11, pp. 1936–1940, 2014.
- [118] K. Gairaa, A. Khellaf, Y. Messlem, and F. Chellali, "Estimation of the daily global solar radiation based on Box-Jenkins and ANN models: A combined approach," *Renew. Sustain. Energy Rev.*, vol. 57, pp. 238–249, 2016.
- [119] J. Li, J. K. Ward, J. Tong, L. Collins, and G. Platt, "Machine learning for solar irradiance forecasting of photovoltaic system," *Renew. Energy*, vol. 90, pp. 542–553, 2016.
- [120] J. I. E. P. Jenson, "Solar radiation forecasting using artificial neural networks," *Natl. Inst. Sp. Res.*, vol. 1, pp. 1–34, 2017.
- [121] S. Sreekumar, K. C. Sharma, and R. Bhakar, "Optimized Support Vector Regression Models for Short Term Solar Radiation Forecasting in Smart Environment," pp. 1929–1932, 2016.
- [122] S. Hussain and A. AlAlili, "A hybrid solar radiation modeling approach using wavelet multiresolution analysis and artificial neural networks," *Appl. Energy*, vol. 208, no. May, pp. 540–550, 2017.
- [123] R. J. Aguiar, M. Collares-Pereira, and J. P. Conde, "Simple procedure for generating sequences of daily radiation values using a library of Markov transition matrices," *Sol. Energy*, vol. 40, no. 3, pp. 269–279, 1988.
- [124] J. Wang, Y. Xie, C. Zhu, and X. Xu, "Solar radiation prediction based on phase space reconstruction of wavelet neural network," *Procedia Eng.*, vol. 15, pp. 4603–4607, 2011.
- [125] P. Zhang, H. Takano, and J. Murata, "Daily Solar Radiation Prediction based on Wavelet Analysis," pp. 712–717, 2011.
- [126] W. Ji and K. C. Chee, "Prediction of hourly solar radiation using a novel hybrid model of ARMA and TDNN," *Sol. Energy*, vol. 85, no. 5, pp. 808–817, 2011.
- [127] M. Ozgoren, M. Bilgili, and B. Sahin, "Estimation of global solar radiation using ANN over Turkey," *Expert Syst. Appl.*, vol. 39, no. 5, pp. 5043–5051, 2012.
- [128] G. Capizzi, C. Napoli, and F. Bonanno, "Innovative Second-Generation Wavelets Construction With Recurrent Neural Networks for Solar Radiation Forecasting," vol. 23, no. 11, pp. 1–11, 2012.
- [129] J. Boland, M. Korolkiewicz, M. Agrawal, and J. Huang, "Forecasting solar radiation on short time scales using a coupled autoregressive and dynamical system (CARDS) model," *Sol. Energy*, vol. 87, no. December, pp. 1–10, 2012.
- [130] L. Lyu, M. Kantardzic, and E. Arabmakki, "Solar Irradiance Forecasting by Using Wavelet Based Denoising," *IEEE Symp. Comput. Intell. Eng. Solut.*, no. 1, pp. 110–116, 2014.
- [131] M. Ghayekhloo, M. Ghofrani, M. B. Menhaj, and R. Azimi, "A novel clustering approach for short-term solar radiation forecasting," *Sol. Energy*, vol. 122, pp. 1371–1383, 2015.
- [132] H. Jiang and Y. Dong, "A nonlinear support vector machine model with hard penalty function based on glowworm swarm optimization for forecasting daily global solar radiation," *Energy Convers. Manag.*, vol. 126, pp. 991–1002, 2016.
- [133] O. Garcia-Hinde *et al.*, "Feature selection in solar radiation prediction using bootstrapped SVRs," *2016 IEEE Congr. Evol. Comput. CEC 2016*, pp. 3638–3645, 2016.
- [134] Y. Gala, ˆ A. Fernˆandez, J. Dıaz, and J. R. Dorrnsoro, "Hybrid machine learning forecasting of solar radiation values," *Neurocomputing*, vol. 176, pp. 48–59, 2016.
- [135] R. C. Deo, X. Wen, and F. Qi, "A wavelet-coupled support vector machine model for forecasting global incident solar radiation using limited meteorological dataset," *Appl. Energy*, vol. 168, pp. 568–593, 2016.
- [136] R. Azimi, M. Ghayekhloo, and M. Ghofrani, "A hybrid method based on a new clustering technique and multilayer perceptron neural networks for hourly solar radiation forecasting," *Energy Convers. Manag.*, vol. 118, pp. 331–344, 2016.
- [137] F. O. Hocaoglu and F. Serttas, "A novel hybrid (Mycielski-Markov) model for hourly solar radiation forecasting," *Renew. Energy*, vol. 108, pp. 635–643, 2017.
- [138] S. M. Mousavi, E. S. Mostafavi, and P. Jiao, "Next generation prediction model for daily solar radiation on horizontal surface using a hybrid neural network and simulated annealing method," *Energy Convers. Manag.*, vol. 153, no. May, pp. 671–682, 2017.

- [139] L. Achour, M. Bouharkat, O. Assas, and O. Behar, "Hybrid model for estimating monthly global solar radiation for the Southern of Algeria: (Case study: Tamanrasset, Algeria)," *Energy*, vol. 135, pp. 526–539, 2017.
- [140] I. A. Ibrahim and T. Khatib, "A novel hybrid model for hourly global solar radiation prediction using random forests technique and firefly algorithm," *Energy Convers. Manag.*, vol. 138, pp. 413–425, 2017.
- [141] J. Heng, J. Wang, L. Xiao, and H. Lu, "Research and application of a combined model based on frequent pattern growth algorithm and multi-objective optimization for solar radiation forecasting," *Appl. Energy*, vol. 208, no. September, pp. 845–866, 2017.
- [142] S. Ramaswamy and P. K. Sadhu, "Forecasting PV Power from Solar Irradiance and Temperature using Neural Networks," pp. 0–4, 2017.
- [143] B. P. Hayes and M. Prodanovic, "State Forecasting and Operational Planning for Distribution Network Energy Management Systems," *IEEE Trans. Smart Grid*, vol. 7, no. 2, pp. 1002–1011, 2016.



**Edgar Darío Obando** Ingeniero Físico de la Universidad del Cauca, y estudiante de Maestría en Ingeniería Eléctrica de la Universidad Nacional de Colombia-Sede Manizales. Sus áreas de interés son las energías alternativas, modelos numéricos y sistemas dinámicos. Consultor y asesor en temas energéticos con fuentes renovables de energía. Miembro del grupo de

investigación E3P: Environmental energy and education policy.



**Sandra Ximena Carvajal** Ingeniera electricista, magíster y PhD en Ingeniería de la Universidad Nacional de Colombia. Actualmente es Profesora Asistente en el Departamento de Ingeniería Eléctrica de la Universidad Nacional de Colombia sede Manizales. Sus áreas de interés incluyen las redes inteligentes de energía eléctrica, los mercados de energía eléctrica y la

Generación Distribuida.



**Jairo Pineda Agudelo** Estadístico de la Universidad Social Católica de La Salle, Especialista en Estadística de la Universidad Nacional y Magister en Desarrollo Regional y Planificación del Territorio, de la Universidad Autónoma de Manizales. Profesor titular de la Universidad de Manizales desde 1989 y Catedrático de la Universidad Nacional

desde 1994. Consultor y asesor empresarial en temas de Análisis de Datos y en Aprendizaje Automático Estadístico. Miembro del grupo de investigación E3P: Environmental energy and education policy.