

DOI: <https://doi.org/10.46296/ig.v7i14.0224>

PRONÓSTICO DE GENERACIÓN FOTOVOLTAICO DE LARGO PLAZO APLICANDO TÉCNICAS DE MACHINE LEARNING

LONG-TERM PHOTOVOLTAIC GENERATION FORECASTING USING MACHINE LEARNING TECHNIQUES

Quinatoa-Lema Freddy ¹; Quinatoa-Caiza Carlos ²

¹ Universidad Técnica de Cotopaxi. Latacunga, Ecuador.

Correo: freddy.quinatoa4942@utc.edu.ec. ORCID ID: <https://orcid.org/0009-0000-6076-0923>.

² Universidad Técnica de Cotopaxi. Latacunga, Ecuador.

Correo: carlos.quinatoa7864@utc.edu.ec. ORCID ID: <https://orcid.org/0000-0001-6369-7480>.

Resumen

En el siguiente proyecto de investigación articula la formulación de un modelo predictivo de recursos solares que emplea metodologías de machine learning a largo plazo donde se construye en fases secuenciales, aprovechando los conceptos pertinentes al análisis de datos históricos y basando su arquitectura en metodologías de machine learning. Se presenta una exposición de la amplia gama de técnicas de machine learning utilizadas en la predicción global de los recursos primarios y se establecen criterios para la selección de técnicas en función de su relevancia para las distintas fases del modelo, también se prepara meticulosamente una síntesis completa sobre la utilización de la estimación y la predicción de los recursos primarios como componentes integrales de la planificación estratégica de los sistemas fotovoltaicos a largo plazo; se formula el modelo y se articulan escenarios de simulación que son pertinentes al clima ecuatoriano, que sirven como un instrumento para estimar el potencial solar que se puede emplear para discernir y enfatizar la importancia de los datos como elementos fundamentales en los procesos de toma de decisiones involucrados en la planificación de las fuentes de energía se caracteriza por la variabilidad de los recursos primarios.

Palabras clave: Sistemas Fovoltaicos, Largo Plazo, Estimación, Potencial Solar.

Abstract

The following subsequent research articulates the formulation of a predictive solar resource model employing long-term machine learning methodologies where it is built in sequential phases, taking advantage of concepts relevant to historical data analysis and basing its architecture on machine learning methodologies. An exposition of the wide range of machine learning techniques used in global primary resource prediction is presented and criteria are established for the selection of techniques based on their relevance to the different phases of the model, a comprehensive synthesis on the use of primary resource estimation and prediction as integral components of long-term strategic planning of photovoltaic systems is also meticulously prepared; the model is formulated and simulation scenarios are articulated that are relevant to the Ecuadorian climate, which serve as a tool for estimating solar potential that can be used to discern and emphasize the importance of data as fundamental elements in the decision-making processes involved in planning energy sources characterized by the variability of primary resources.

Keywords: Photovoltaic Systems, Long-term, Estimate, Solar Potential.

Información del manuscrito:

Fecha de recepción: 15 de abril de 2024.

Fecha de aceptación: 25 de junio de 2024.

Fecha de publicación: 10 de julio de 2024.



1. Introducción

Esta investigación académica se centra en el examen de la predicción temporal extendida de la producción de energía fotovoltaica mediante la aplicación de metodologías de machine learning, ya que la actual transición energética hacia fuentes renovables se ve obstaculizada significativamente por la mayoría predominante de las naciones (Chen et al., 2011). En consecuencia, la generación de energía fotovoltaica adquiere una importancia fundamental; sin embargo, la producción derivada de una instalación solar fotovoltaica depende de variables externas, incluidas las condiciones meteorológicas y la radiación solar, lo que hace que su pronóstico sea complejo: las características variables e intermitentes de la energía solar, influenciadas por las condiciones climáticas, presentan obstáculos considerables en la planificación estratégica de la integración efectiva a largo plazo de las fuentes de energía renovables en la red eléctrica (Voyant et al., 2017). Es imprescindible poseer datos precisos y completos sobre el potencial solar. Esto permite la

utilización óptima de las capacidades que presentan las diversas regiones geográficas. Inicialmente, se lleva a cabo un examen exhaustivo de los conceptos fundamentales necesarios para el estudio, incluidas las definiciones y los atributos del recurso principal, junto con las variables pertinentes a dicho recurso. El machine learning (ML) constituye un subconjunto de la inteligencia artificial, aplicable en múltiples dominios, y su principal ventaja es su capacidad para abordar problemas que no se pueden representar mediante algoritmos explícitos. Los modelos de machine learning distinguen las relaciones entre las entradas y las salidas, incluso en escenarios en los que la representación es inalcanzable. Esta característica facilita la aplicación de los modelos de machine learning en numerosos contextos, particularmente en la previsión de desafíos. En este marco en particular, es imprescindible investigar la metodología de aprendizaje profundo denominada transformador de fusión temporal (TFT) (Chen et al., 2011). El algoritmo TFT asimila los datos históricos de producción y los integra con variables como la irradiación, los

ángulos solares, la temperatura, la humedad, la velocidad del viento y las precipitaciones, entre otras, para mejorar la precisión de las previsiones a largo plazo relacionadas con la generación de energía fotovoltaica (Anuradha et al., 2021). Las metodologías innovadoras relacionadas con la previsión de la generación influyen significativamente en la planificación y la gestión de la energía, ya que facilitan predicciones más precisas de la producción de energía solar y mejoran la gestión de la variabilidad de la producción (Sharkawy et al., 2022). La precisión mejorada de la previsión algorítmica en Python contribuye a la minimización de los gastos y al aumento de la eficiencia operativa, mientras que las metodologías de aprendizaje profundo, debido a su capacidad para analizar y obtener información de extensos repositorios de datos, proporcionan los instrumentos necesarios para abordar este desafío (Voyant et al., 2017). Paralelamente, se analiza y selecciona meticulosamente la base de datos que aborda de manera más eficaz los requisitos de la investigación, junto con la

identificación de las áreas de estudio relevantes.

Tras obtener la información necesaria a partir de los datos de entrada y delimitar las zonas definidas para facilitar la aplicación de las metodologías de machine learning, se evalúan posteriormente varias técnicas para determinar su eficacia en la clasificación y la regresión, junto con una revisión exhaustiva del modelo híbrido. Tras el establecimiento de las metodologías elegidas, el modelo híbrido se construye sistemáticamente, delineando cada una de las etapas que lo constituyen, al mismo tiempo que se realizan las calibraciones de los parámetros esenciales para mejorar su eficacia operativa; posteriormente, utilizando el modelo desarrollado, se derivan los hallazgos y conclusiones resultantes.

2. Materiales y métodos

El dominio de las fuentes de energía renovables, en particular el despliegue de energía solar para la generación de energía eléctrica, ha experimentado importantes avances tecnológicos en los últimos años

(Chen et al., 2011), lo que se ha traducido en un aumento notable en la utilización de instalaciones solares fotovoltaicas vinculadas a la red eléctrica externa, que ha experimentado un aumento mundial en el año 2021 (Voyant et al., 2017). La energía solar presenta una variabilidad significativa, ya que se genera mediante la conversión de la radiación solar en energía eléctrica utilizable a través de paneles fotovoltaicos que aprovechan la irradiación solar (Voyant et al., 2017). La predicción de la radiación solar depende de una multitud de variables, tan variables como las condiciones meteorológicas que influyen en la magnitud, la duración y la trayectoria de la irradiación solar (Anuradha et al., 2021). La energía producida por las instalaciones solares fotovoltaicas está influenciada por las variaciones climáticas, en particular la irradiación solar y la temperatura ambiente; por lo tanto, para evaluar la estabilidad y confiabilidad del sistema eléctrico, es imperativo generar pronósticos para esta producción de energía, teniendo en cuenta los datos históricos relacionados con las variables climáticas (Sharkawy et al., 2022). Este análisis predictivo también

ayudaría en la administración y el mantenimiento de estas instalaciones solares fotovoltaicas (Aparicio, 2020).

Predicción de radiación solar

El machine learning representa un dominio especializado dentro de la disciplina más amplia de la informática y se identifica como una técnica pertinente a la inteligencia artificial (IA). Esta metodología encuentra aplicaciones en una amplia gama de sectores, que abarcan la energía, la economía y la biología (Castillo, 2015). El proceso de machine learning se divide en tres fases distintas: la fase inicial implica el pre procesamiento y la clasificación de los datos, la fase posterior se refiere a la entrada de datos y la fase final aborda las discrepancias entre los datos pronosticados y los datos medidos reales.

Además, la implementación de un modelo de aprendizaje automático requiere la consideración de criterios específicos, como se describe en (Echegaray et al., 2018):

- Tratamiento de la no-linealidad.
- Comportamiento al usar múltiples entradas.

- Horizonte de predicción.
- Tratamiento de la desviación asociada a la predicción
- Flexibilidad

En el ámbito de la predicción de la radiación solar, la aplicación del machine learning ha demostrado un impacto transformador a la hora de abordar los desafíos que plantean la importante falta de linealidad inherente a los datos y su pronunciada variabilidad (Echegaray et al., 2018).

Estimación de recurso primario aplicado en escenarios de planeación

La evaluación del recurso solar primario se convierte en un instrumento fundamental dentro de la planificación estratégica del sector eléctrico. Los responsables políticos dependen cada vez más de los análisis técnicos, tanto para cuantificar el recurso primario como para guiar la formulación de políticas destinadas a establecer el marco y las iniciativas para el avance de la energía solar fotovoltaica (Constante & Palacios, 2014). En el contexto de la planificación de un sistema fotovoltaico, cuatro fases distintas

requieren una evaluación exhaustiva (Sandoval Serrano, 2018):

1. Planeación de generación a largo plazo, con un periodo de 10 a 40 años.
2. Planeación geo-espacial para transmisión, Un periodo de tiempo de 5-20 años.
3. Simulación de despacho, con un tiempo no mayor a semanas o meses.
4. Estudios técnicos de red, con un tiempo mayor a 5 años.

En consecuencia, se pueden identificar tres categorías distintas de radiación con respecto a los impactos que la radiación solar ejerce sobre la Tierra:

- **Directa:** radiación que se origina en el sol sin sufrir ninguna alteración por las condiciones atmosféricas de la Tierra (Echegaray et al., 2018).
- **Difusa:** se refiere a la radiación que presenta una variabilidad de dirección como resultado de los fenómenos de dispersión que experimenta en la atmósfera o que, alternativamente, está influenciada por el efecto albedo (Echegaray et al., 2018).
- **Energía reflejada:** se refiere a la parte de la energía solar que

impacta directamente en la superficie terrestre y, posteriormente, se refleja en las superficies adyacentes o se reemite a la atmósfera (Cuesta et al., 2023). Haciendo hincapié en las categorías antes mencionadas, se puede afirmar que, en el contexto del aprovechamiento de la radiación solar en las instalaciones de energía fotovoltaica y foto térmica, la radiación directa tiene una importancia capital. Numerosos factores contribuyen

a la atenuación de la radiación directa, que puede deberse a las condiciones meteorológicas, los días nublados u otras variables. No obstante, la radiación continúa absorbiéndose, ya que la radiación difusa está permanentemente presente y activa. Para dilucidar más, la suma de los tres tipos de radiación (directa, difusa y reflejada) constituye la radiación total que impregna nuestro planeta (Cuesta et al., 2023). En la Figura 1 se observa a detalle:

Figura 1. Tipos de radiación solar



Fuente: (Cuesta et al., 2023)

Para aprovechar la energía eléctrica derivada de la radiación solar, es imprescindible convertirla mediante módulos fotovoltaicos, aprovechando las propiedades excepcionales de estos materiales

semiconductores que son capaces de absorber, conducir o aislar la energía.

Tras la interacción de la célula fotovoltaica con los fotones (partículas de luz), se produce una

transferencia de energía a los electrones dentro del material de la célula, lo que resulta en una elevación de los niveles de energía entre los electrones, lo que permite su movilidad por todo el material (Echegaray et al., 2018) ; cada electrón llega posteriormente a un punto de contacto designado, que culmina con la generación de una corriente eléctrica (Cuesta et al., 2023).

Machine Learning


El machine learning puede caracterizarse como la metodología computacional de deducir y extrapolar de forma autónoma un modelo de aprendizaje a partir de una muestra de conjunto de datos, como se muestra en la Figura 2 (Sandoval Serrano, 2018). Estos modelos emplean algoritmos, o funciones estadísticas, para delinear las dependencias dentro de los datos, las ocurrencias y las correlaciones entre las variables de entrada y los resultados de salida (Voyant et al., 2017). Existen dos categorías distintas de aprendizaje: supervisado y no supervisado.

Aprendizaje supervisado: en este paradigma de aprendizaje, un algoritmo se somete a un proceso de

entrenamiento mediante el cual se le proporcionan tanto las preguntas (características) como las respuestas correspondientes. Esto permite al algoritmo ejecutar posteriormente predicciones en función de su comprensión de las características (Bontempi et al., 2013). En este marco, se emplean algoritmos de clasificación y regresión.

Algoritmos de clasificación: estos algoritmos identifican los patrones subyacentes dentro de los datos suministrados y los clasifican en distintos grupos, evaluando posteriormente los datos novedosos asignándolos a una de estas categorías establecidas, dotándolos así de capacidades predictivas (Bontempi et al., 2013).

Figura 2. Clasificación lineal




Fuente:(Bontempi et al., 2013)

El machine learning clasifica los modelos en función de la cantidad de metodologías empleadas. Cuando se utiliza una metodología aislada desde la entrada inicial de datos hasta la fase final, normalmente en ausencia de procesamiento previo, se denomina modelo unitario. Por el contrario, cuando se implementan dos o más metodologías en cada etapa, junto con el procesamiento de datos, se designa como modelo híbrido (Sandoval Serrano, 2018).

Redes Neuronales

Esta metodología tiene como objetivo emular las características operativas del cerebro humano, que consiste en numerosas neuronas interconectadas que forman redes que facilitan la transmisión de información entre ellas, como se muestra en la Figura 3. Esta simulación del funcionamiento cerebral humano se clasifica como uno de los modelos de moda contemporáneos debido a las avanzadas capacidades de razonamiento cognitivo que desarrolla (Bontempi et al., 2013).

Figura 3. Estructura de la red neuronal artificial



Fuente: (Bontempi et al., 2013)

SVM


Las máquinas vectoriales de soporte Support Vector Machine (SVM) se esfuerzan por identificar un hiperplano de delineación que

mantenga una distancia igual de las instancias más cercanas (muestras o vectores de entrada) de cada categoría, logrando así lo que se conoce como el margen máximo a cada lado del hiperplano. Al definir

este hiperplano, solo se tienen en cuenta las instancias de entrenamiento de cada categoría

que están ubicadas precisamente en el límite de estos márgenes. Como se muestra en la Figura 4.

Figura 4. Clases de un hiperplano equidistantes en SVM



Fuente: (Aparicio, 2020)

Las máquinas vectoriales de soporte (SVR) que se han modificado para abordar los desafíos de regresión (regresión vectorial de soporte). Por lo tanto, teniendo en cuenta una colección de instancias de formación:

$$S = \{(x_1, y_1), \dots, (x_n, y_n)\} \quad (1)$$

El sector eléctrico una oportunidad para el ML

Inicialmente, la aplicación de modelos empíricos basados en la evaluación de las correlaciones entre las variables meteorológicas y el análisis de imágenes de satélite (Bontempi et al., 2013) culmina con la creación de instrumentos como los mapas, que dilucidan el potencial de

los recursos solares y facilitan la formulación de estrategias de expansión de la generación a largo plazo. En el funcionamiento del sistema eléctrico, una de las consideraciones fundamentales es garantizar el equilibrio entre la oferta y la demanda, garantizando esencialmente que la generación se alinee con el consumo en tiempo real. Esto requiere la realización de estudios destinados a mantener la estabilidad del sistema y la frecuencia de la red, además de comprender el comportamiento de sus componentes y variables, como el voltaje, la corriente eléctrica y la potencia, mediante metodologías

como el análisis del flujo de carga (Echegaray et al., 2018).

La incorporación de estas fuentes de generación renovables a la matriz energética (específicamente la solar y la eólica) presenta importantes ventajas para los gobiernos contemporáneos, ya que estas fuentes disminuyen la dependencia de las fuentes de energía tradicionales y mitigan la necesidad de adquirir combustible para las centrales térmicas. Además, además de las ventajas ambientales bien documentadas, contribuyen a la reducción de las emisiones de gases de efecto invernadero, a la mejora de la calidad del aire mundial y a la disminución del consumo de agua por unidad de electricidad generada (Echegaray et al., 2018). El panorama contemporáneo de los sistemas fotovoltaicos en Ecuador se caracteriza por un avance sustancial en la utilización de la energía solar, respaldado por políticas gubernamentales favorables e innovaciones tecnológicas; sin embargo, al mismo tiempo encuentra obstáculos relacionados con la integración dentro de la red eléctrica y la viabilidad financiera (Sandoval Serrano, 2018).

La nación exhibe atributos geográficos y climáticos distintivos que pueden afectar significativamente el despliegue de los sistemas fotovoltaicos. El potencial de energía solar en Ecuador es excepcionalmente alto, lo que se atribuye a su posición dentro de la zona intertropical, con una insolación solar promedio de 4.378 (kW-h/m² por día). El punto álgido de la radiación solar en el país se observa en la región andina, donde la elevación facilita la absorción de niveles sustanciales de energía solar a lo largo del ciclo anual. La capacidad fotovoltaica en Ecuador, tal como se define en la designación de tierra adecuada para el desarrollo de instalaciones fotovoltaicas complementarias, comprende el 9,3% de la extensión nacional (23.819 km²), mientras que el área clasificada como tierra más adecuada para tales desarrollos abarca 805 km² o el 0,32% del territorio nacional, lo que arroja un potencial bruto teórico de 35,7 GWp (61,5 GWh/año). La radiación solar emitida por el sol entra en la atmósfera terrestre en una fracción relativamente pequeña en comparación con la producción solar total debido a las grandes distancias

recorridas; la cifra aproximada de la radiación solar que incide sobre la Tierra es de $1.360 \text{ (W/m}^2\text{)}$. Sin embargo, este valor no refleja la radiación que finalmente llega a la superficie terrestre, ya que aproximadamente el 26% de los 1360 W/m^2 se absorbe dentro de la capa atmosférica, lo que hace que una radiación solar efectiva de aproximadamente 1000 W/m^2 llegue a la superficie.

3. Resultados y discusión

Para el avance de estos modelos, un requisito fundamental es la posesión de datos históricos validados que faciliten la comprensión de la interdependencia estocástica entre los eventos pasados y los resultados futuros. Esta capacidad de analizar datos y convertir las observaciones en conocimiento práctico nos permite crear modelos sólidos con niveles de precisión aceptables. Sin embargo, para el desarrollo de estos modelos, es imprescindible tener en cuenta las metodologías incluidas en el machine learning, ya que cada técnica posee atributos distintivos que la hacen más competente en relación con las aplicaciones específicas y las configuraciones

que se les atribuyen. En el presente estudio, la aplicación del machine learning se concentra en la predicción de los recursos solares primarios como fuentes de energía renovables no tradicionales, lo que permite evaluar el potencial energético dentro de una localidad geográfica designada, ofreciendo así una metodología que ayuda en la fase de diseño para mitigar la incertidumbre relacionada con el recurso energético.

Base de datos

En el contexto de las bases de datos disponibles actualmente en la Tabla 1, se consideró necesaria una revisión exhaustiva de las fuentes nacionales e internacionales. En el marco nacional, se identifica la base de datos IDEAM, mientras que entre las fuentes internacionales destacan organizaciones como la NASA. A la luz de los atributos de las bases de datos mejoradas, cabe destacar que la NASA presenta importantes ventajas con respecto al IDEAM en lo que respecta a la actualidad de la información, reduce los casos de datos ausentes para las variables de entrada y salida y aumenta la eficiencia en la gestión de los datos faltantes para un pre procesamiento

adecuado de la información. En consecuencia, se considera que la base de datos de la NASA se ajusta mejor a los requisitos del estudio, lo

que confirma su papel como fuente fiable de información para fundamentar el modelo.

Tabla 1. Características de los datos de las variables de la NASA

Parámetro	Unidades	Abreviatura
Precipitación diaria	Mm/día	PRECTOT
Precipitación atmosférica	kPa	PS
Humedad relativa	%	RH2M
Temperatura media	°C	T2M
Velocidad del viento	m/s	WS10M
Índice de claridad	Adimensional	KT
Radiación a cielo abierto	W/m^2	ALLKY_SFC_SW_DWN

Desarrollo del modelo

Teniendo en cuenta los factores antes mencionados, procedemos ahora a seleccionar las metodologías que constituirán el modelo definitivo. Para este emprendimiento, se emplea el lenguaje de programación Python, que se caracteriza por ser de código abierto y diseñado para analistas de datos. En el ámbito de la programación, las variables se

asocian a entidades específicas, y cabe destacar que cada lenguaje de programación posee un enfoque único para la implementación del concepto de variable. Python abarca varios tipos de variables que los expertos pueden utilizar de forma predeterminada, incluidos, entre otros: tipos numéricos, secuencias, mapeos y conjuntos, que sirven para organizar otros datos, como se explica en la siguiente Tabla 3 a continuación.

Tabla 2. Principales funciones utilizados

Tipo de variable	Descripción
def	Sirve para crear funciones definidas por el usuario.
if	Se usa para tomar decisiones, generalmente de una operación lógica


else	Se cumple sin evaluar la expresión condicional
Open, read	Permite abrir archivo y leer archivo.

Este lenguaje de programación abarca una serie de funciones que están integradas de forma inherente

en el propio lenguaje y, al mismo tiempo, facilitan el desarrollo de funciones definidas por el usuario.

Flujo del programa desarrollado

Figura 5. Estructura de la metodología aplicada



Fuente: Autoría propia

La Figura 5 delinea la representación esquemática del aparato computacional ideado, en el que el procesamiento de variables estocásticas (específicamente la radiación solar y la temperatura) junto con una evaluación probabilística precisa mediante la simulación del machine learning produce la potencia de salida proyectada que la instalación fotovoltaica es capaz de entregar

durante un período de análisis específico.

Para determinar la producción eléctrica que generará la instalación de energía solar fotovoltaica, es imprescindible establecer una previsión de los recursos primarios (Figura 6), ya que se trata de variables que son intrínsecamente susceptibles a las fluctuaciones naturales que escapan al control humano, lo que presenta un desafío importante en el cálculo de la

producción de energía de dichos sistemas de generación eléctrica. El conjunto de datos relativo a la radiación solar y la temperatura proviene del laboratorio de Energía Renovable de la Escuela Politécnica Nacional. Es importante hacer hincapié en que la gestión eficaz de los datos requiere la disponibilidad de un conjunto de datos anual para garantizar que los cálculos

posteriores arrojen una estimación energética que se ajuste sustancialmente a las condiciones reales; además, el intervalo designado de horas representativas para la gestión de datos se estableció entre las 07:00 y las 18:00 horas, lo que culminó con un total de 12 horas asignadas a la estimación de la energía.

Figura 6. La irradiación solar promedio




Fuente: Autoría propia

Para el examen del histograma, tenemos en cuenta la tabla de datos que presenta la irradiación media mensual junto con la curva

correspondiente que ilustra las fluctuaciones en la irradiación diaria total.

Figura 7. Potencia generada y predicción para un día soleado




Fuente: Autoría propia

La Figura 7 presentan el análisis comparativo de los resultados predictivos yuxtapuestos con el conjunto de datos original en un día caracterizado por cielos despejados y otro marcado por condiciones sustancialmente nubladas, respectivamente. Estas representaciones gráficas aclaran la eficacia del modelo a la hora de pronosticar la energía eléctrica generada, teniendo en cuenta las variables que se han tenido en

cuenta. Los atributos eléctricos de un módulo de potencia y voltaje están determinados por las células fotovoltaicas que lo constituyen, como lo ilustran las curvas P-V e I-V, y se especifican mediante los parámetros I_{sc} (corriente de cortocircuito), V_{oc} (voltaje de circuito abierto), V_{mpp} (voltaje máximo), I_{mpp} (corriente máxima), P_m (potencia máxima) y FF (factor de llenado).

Figura 8. Los valores de I_{sc} , V_{oc} , V_{mpp} , I_{mpp}



Fuente: Autoría propia


Los parámetros en la Figura 8, I_{sc} , V_{oc} , V_{mpp} e I_{mpp} se calcularon en condiciones de prueba estándar, que se describen de la siguiente manera: irradiación $G = 1 \text{ kW/m}^2$, distribución espectral AM = 1,5 y temperatura de la celda $T_c = 25 \text{ }^\circ\text{C}$. La potencia máxima de salida del módulo, tal como se define en las condiciones de prueba estándar (STC), se

denomina potencia máxima y se cuantifica en vatios máximos (Wp). El impacto de la temperatura y la irradiación en el rendimiento de la célula solar es de suma importancia para las predicciones precisas; por lo tanto, confiar únicamente en un modelo físico no sería práctico. Por el contrario, se emplean metodologías matemáticas para

convertir las características de corriente-voltaje (I-V) del STC en distintos puntos de funcionamiento, aunque dentro de rangos de temperatura e irradiación específicos próximos a los valores de prueba, incorporando al mismo tiempo parámetros adicionales. Este modelo analítico se estructura en dos fases: la fase inicial utiliza redes neuronales (NN) para estimar los valores mensuales de la radiación solar. La fase posterior implica la

normalización de los valores de radiación, que sirven como entradas a la matriz de Markov. La desviación observada en esta investigación es de aproximadamente el 8% en comparación con los modelos lineales y estadísticos. Este marco analítico es experto en capturar las características no lineales de la radiación y sopesar eficazmente las probabilidades de ocurrencia para identificar el predictor.

Figura 9. Componentes del predictor principal híbrido



Fuente: (Chen et al., 2011)

La fase de pronóstico que utiliza SVM en la Figura 9, comienza evaluando un mapeo del conjunto de datos de entrada dentro de un dominio expansivo delineado por la función del kernel. Esta función calcula el producto interno entre las representaciones de dos puntos de datos distintos. El proceso de aprendizaje se lleva a cabo dentro

del espacio de características, donde los puntos de datos se representan exclusivamente a través de sus productos internos con otros puntos.

Según el marco teórico, si se utilizara una proyección:

$\Phi \rightarrow$ Aquí, x indica el vector de datos de entrada y representa el hiperplano separador.

El producto interno de los puntos

La función k del núcleo puede articularse mediante una función básica k .

$$k(x, x') = \langle \Phi(x) | \Phi(x') \rangle \quad (2)$$

Una vez que se ha delineado la función del núcleo de tipo red neuronal (NN), es factible operar dentro de espacios de cualquier dimensionalidad sin necesidad de repetir el procedimiento de caracterización. Esta capacidad se basa en la capacidad de las redes neuronales para asimilar numerosas entradas que pueden utilizarse directamente con conjuntos de datos alternativos, lo que evita la necesidad de utilizar una metodología de extracción de características.

En última instancia, determina los valores de la radiación total incidente como consecuencia del análisis predictivo. Las secciones siguientes aclaran los escenarios de simulación y las características operativas del modelo de inteligencia artificial en diferentes perfiles climáticos.

4. Conclusiones

Se estableció una metodología de vanguardia en la que se discernieron los patrones evolutivos al abordar el tema de la previsión de los recursos primarios, y las soluciones delineadas en la literatura existente empleaban predictores de aprendizaje automático. Se formuló un marco híbrido basado en metodologías de machine learning para evaluar y estimar cuantitativamente el recurso solar diario utilizando el lenguaje de programación Python.

Al seleccionó meticulosamente una base de datos adaptada a los requisitos de la investigación (NASA), que se considera más sólida y funcional en comparación con las bases de datos alternativas, se ajustó a la metodología propuesta para su aplicación en este contexto específico y, basándose en este conjunto de datos, se analizó la capacidad de respuesta del modelo a las diversas condiciones meteorológicas en relación con cada área de estudio designada. El machine learning facilita la toma de decisiones estratégicas a largo plazo, lo que permite proporcionar soluciones cada vez más eficientes

en relación con la capacidad de generación de los sistemas fotovoltaicos, además de discernir los tiempos óptimos para que los sistemas antes mencionados se interconecten a la red, mejorando así la confiabilidad de la infraestructura eléctrica.

En última instancia, la incorporación de técnicas de machine learning en la planificación estratégica de la toma de decisiones plantea un desafío importante en las iniciativas de expansión en Ecuador. Comprender el contexto histórico de una región y evaluar su potencial como recurso principal contribuirá a tomar decisiones más informadas en las dimensiones económica, de inversión y social.

Bibliografía

- Anuradha, K., Erlapally, D., Karuna, G., Srilakshmi, V., & Adilakshmi, K. (2021). Analysis Of Solar Power Generation Forecasting Using Machine Learning Techniques. *E3S Web of Conferences*, 309. <https://doi.org/10.1051/e3sconf/202130901163>
- Aparicio, M. P. (2020). Solar radiation and its energy use. Marcombo.
- <https://books.google.com.ec/books?id=YkxOEAAAQBAJ>
- Bontempi, G., Ben Taieb, S., & Le Borgne, Y.-A. (2013). Machine Learning Strategies for Time Series Forecasting. In *Lecture Notes in Business Information Processing* (Vol. 138, p. 6). https://doi.org/10.1007/978-3-642-36318-4_3
- Castillo, J. I. R. (2015). Analysis of the operation of photovoltaic panels and their use in the coastal and highland regions of Ecuador, case study: Pompeu Fabra Library in Mataró. 99. <https://api.semanticscholar.org/CorpusID:161044152>
- Chen, J.-L., Liu, H.-B., Wu, W., & Xie, D.-T. (2011). Estimation of monthly solar radiation from measured temperatures using support vector machines – A case study. *Renewable Energy*, 36(1), 413–420. <https://doi.org/https://doi.org/10.1016/j.renene.2010.06.024>
- Constante, J., & Palacios, E. (2014). Solar Resource For Power Generation. In *Universidad Politécnica Salesiana*. <http://www.dspace.ups.edu.ec/handle/123456789/6791>
- Cuesta, M., Constante, J., & Jijón, D. (2023). Solar Radiation and Ambient Temperature Prediction Modeling by Recurrent Neural Networks.

Revista Técnica "Energía,"
19(2), PP. 81–89.
<https://doi.org/10.37116/revistaenergia.v19.n2.2023.552>

Echegaray, C., Masabanda-Caisaguano, M., Rodriguez Espinosa, F., Toulkeridis, T., Mato, F., & Alegria, A. (2018). Solar Energy Potential in Ecuador. Proceedings of the IEEE, 1, 46–51.
<https://doi.org/10.1109/ICEDEG.2018.8372318>

Sandoval Serrano, L. J. (2018). Machine learning algorithms for data analysis and forecasting. Revista Tecnológica, 11, 1–2.
http://redicces.org.sv/jspui/bitstream/10972/3626/1/Art6_RT2018.pdf

Sharkawy, A.-N., Ali, M., Mousa, H., Ali, A., & Abdel-Jaber, G. (2022). Machine Learning Method for Solar PV Output Power Prediction. SVU-International Journal of Engineering Sciences and Application, 3(1), 123–130.
<https://doi.org/10.21608/svusc.2022.157039.1066>

Voyant, C., Notton, G., Kalogirou, S., Nivet, M.-L., Paoli, C., Motte, F., & Fouilloy, A. (2017). Machine Learning methods for solar radiation forecasting: a review. Renewable Energy, 105.
<https://doi.org/10.1016/j.renene.2016.12.095>