

**Diseño, construcción y evaluación comparativa de un seguidor solar bifacial con algoritmos de control astronómico y aprendizaje automático basado en datos meteorológicos**

Hermes Augusto Pinto Nieves

Asesor

Jairo Luis Gutiérrez Torres

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas, Tecnología e Ingeniería - ECBTI

Ingeniería Electrónica

2026

## Resumen

El presente trabajo desarrolla un sistema de seguimiento solar bifacial de doble eje utilizando componentes de bajo costo, comparando experimentalmente el desempeño de un algoritmo de control por seguimiento astronómico y otro de optimización mediante aprendizaje automático. El sistema incorpora un panel superior de 30W y uno inferior de 8W simulando una configuración bifacial. El algoritmo astronómico calcula la posición solar teórica mediante la librería PVLIB de Python, transformando las coordenadas esféricas (acimut y cenit) al sistema de referencia cartesiano del seguidor. El método de aprendizaje automático utiliza un modelo Random Forest entrenado con datos meteorológicos históricos del NSRDB y alimentado en tiempo real con información de Open-Meteo, actualizando el posicionamiento cada 15 minutos. Se realizaron mediciones continuas durante 5 días para cada método en períodos diferentes, registrando generación energética, consumo de actuadores, sistema de control y ángulos de posicionamiento. Los resultados evidencian que el método de aprendizaje automático generó 95.91 Wh/día comparado con 77.07 Wh/día del astronómico, representando un incremento del 24.4% en generación total y 2% en energía neta. Esta superioridad se atribuye a la capacidad del modelo de optimizar el posicionamiento para condiciones de radiación difusa predominantes durante los días nublados del período experimental. Aunque las mediciones no fueron simultáneas y las condiciones meteorológicas variaron entre períodos, ambos enfrentaron predominantemente días nublados con solo dos días completamente soleados. El análisis proyecta que en sistemas de mayor escala estas ventajas serían proporcionalmente superiores, estableciendo al aprendizaje automático como estrategia viable para maximizar captación solar en regiones con condiciones meteorológicas variables.

**Palabras clave:** Seguimiento, Fotovoltaica, Bifacial, Aprendizaje Automático.

## Abstract

This work develops a dual-axis bifacial solar tracking system using low-cost components, experimentally comparing the performance of two control approaches: an astronomical tracking algorithm and an optimization method based on machine learning. The system incorporates a 30W upper panel and an 8W lower panel, emulating a bifacial configuration. The astronomical algorithm calculates the theoretical solar position using the PVLIB Python library and transforms the spherical coordinates (azimuth and zenith) into the tracker's Cartesian reference system. The Machine Learning method uses a Random Forest model trained with historical meteorological data from NSRDB and fed in real-time with information from Open-Meteo, updating positioning every 15 minutes. Continuous measurements were conducted over 5 days for each method during different periods, recording energy generation, actuator consumption, control system, and positioning angles. The results show that the machine learning method produced 95.91 Wh/day, compared to 77.07 Wh/day for the astronomical method, representing a 24.4% increase in total energy generation and a 2% increase in net energy. This superiority is attributed to the model's ability to optimize positioning under diffuse-radiation conditions, which predominated during the cloudy days of the experimental period. Although measurements were not simultaneous and meteorological conditions varied between periods, both faced predominantly cloudy days with only two completely sunny days. The analysis projects that in larger-scale systems, these advantages would be proportionally greater, establishing Machine Learning as a viable strategy for maximizing solar capture in regions with variable meteorological conditions.

**Keywords:** Tracking, Photovoltaic, Bifacial, Machine-learning.

## Tabla de Contenido

Introducción.....	11
Justificación.....	14
Objetivos.....	17
Objetivo General.....	17
Objetivos Específicos.....	17
Marco de Referencia.....	18
Marco Teórico.....	18
Paneles Solares Bifaciales.....	18
Seguidores Solares.....	19
Sistemas Fotovoltaicos de Ángulo Fijo.....	19
Seguidores Solares de un Solo Eje.....	19
Seguidores Solares de Doble Eje.....	20
Accionamiento de un Seguidor Solar.....	21
Seguidores Solares Pasivos.....	21
Seguidores Solares Activos.....	22
Radiación Solar.....	22
Irradiancia Horizontal Global (GHI).....	23
Irradiancia Horizontal Difusa (DHI).....	23
Irradiancia Normal Directa (DNI).....	23
Aprendizaje Automático.....	24
Bosque Aleatorio o Random Forest.....	25
Minimum Redundancy Maximum Relevance (mRMR) para Random Forest.....	26

Marco Legal.....	28
Normativa Colombiana Aplicable.....	28
Ley 1715 de 2014.....	28
Reglamento Técnico de Instalaciones Eléctricas (RETIE).....	28
Norma Técnica Colombiana NTC 2050 o Código Eléctrico Colombiano.....	29
Regulación sobre Autogeneración y Generación Distribuida.....	29
Estándares Internacionales para Seguidores Solares.....	30
IEC 62817 – “Photovoltaic Systems – Design Qualification of Solar Trackers”.....	30
Certificación UL 3703 (Estados Unidos).....	31
Consideraciones Éticas y de Uso de Datos.....	32
Antecedentes.....	33
Estado del Arte.....	35
Metodología.....	38
Planteamiento y Diseño.....	38
Adquisición y Preparación de Datos para el Modelo.....	40
Desarrollo y Entrenamiento del Modelo.....	41
Implementación en Hardware y Control en Tiempo Real.....	43
Pruebas y Ajustes.....	46
Mediciones de Generación de Energía.....	47
Análisis Financiero Comparativo Entre el Seguimiento Astronómico y el Machine Learning.....	48
Análisis de Resultados.....	50
Algoritmo de Control y Simulación.....	50
Modelo Random Forest de Posicionamiento.....	52

Prototipo Construido del Seguidor Solar.....	54
Resultados de Mediciones.....	58
Generación Energética.....	58
Consumo Energético del Sistema.....	60
Consumo de los Actuadores Lineales.....	60
Consumo del Sistema de Control.....	61
Consumo Total del Sistema.....	61
Eficiencia Neta del Sistema.....	62
Análisis del Comportamiento Angular.....	63
Ángulo Este-Oeste (Movimiento en Dirección EO).....	63
Ángulo Norte-Sur (Movimiento en Dirección NS).....	65
Análisis Financiero Comparativo Entre Métodos de Seguimiento.....	66
Sistema Escalado de Mayor Potencia.....	66
Conclusiones.....	71
Recomendaciones.....	74
Referencias Bibliográficas.....	76

## Lista de Tablas

<b>Tabla 1</b>	<i>Variación de Presupuesto para una Generación de Pequeña Escala Durante 10 Años</i>	68
<b>Tabla 2</b>	<i>Comparación de las Alternativas de Seguimiento Solar .....</i>	70
<b>Tabla 3</b>	<i>Costos de Estructura y Componentes Generales del Seguidor Solar de 1200W .....</i>	89

## Lista de Figuras

<b>Figura 1</b> <i>Posicionamiento de un Seguidor Solar de Doble Eje Durante el Día</i> .....	20
<b>Figura 2</b> <i>Componentes de la Radiación Solar</i> .....	24
<b>Figura 3</b> <i>Esquema General de la Simulación del Control del Seguidor Solar en Simulink</i> .....	39
<b>Figura 4</b> <i>Visor de la Base de Datos NSRDB del NREL</i> .....	40
<b>Figura 5</b> <i>Paso a Paso para Calcular las Posiciones Objetivo del Entrenamiento</i> .....	42
<b>Figura 6</b> <i>Estructura del Seguidor Solar</i> .....	45
<b>Figura 7</b> <i>Circuito Inicial de Control y Lectura de Datos</i> .....	46
<b>Figura 8</b> <i>Algoritmo de Control del Seguidor Solar en Simulink</i> .....	50
<b>Figura 9</b> <i>Posición Simulada en Simulink del Panel Solar para un Día de Prueba</i> .....	51
<b>Figura 10</b> <i>Simulación del Movimiento del Seguidor Solar en Simulink</i> .....	51
<b>Figura 11</b> <i>Correlación de Variables Seleccionadas</i> .....	52
<b>Figura 12</b> <i>Resultados y Prueba de Modelos Entrenados</i> .....	53
<b>Figura 13</b> <i>Planos del Circuito Electrónico Usando la Tarjeta Arduino Uno R4 Wifi</i> .....	56
<b>Figura 14</b> <i>Seguidor Solar Operando en Condiciones de Nubosidad</i> .....	57
<b>Figura 15</b> <i>Sistema Conectado a un SBC de Bajo Costo</i> .....	58
<b>Figura 16</b> <i>Potencia de los Paneles Superior e Inferior</i> .....	59
<b>Figura 17</b> <i>Potencia Instantánea Total del Sistema (Panel Superior + Inferior)</i> .....	60
<b>Figura 18</b> <i>Consumo Medio Instantáneo de los Actuadores Lineales</i> .....	61
<b>Figura 19</b> <i>Eficiencia Neta del Sistema (Generación - Consumo Motores)</i> .....	62
<b>Figura 20</b> <i>Ángulo de Posicionamiento del Seguidor Solar</i> .....	64
<b>Figura 21</b> <i>Pantalla de Registro de Mediciones en el Día 26/10/2025</i> .....	87
<b>Figura 22</b> <i>Seguidor Solar Bajo Condiciones de Nubosidad</i> .....	88

**Figura 23** *Pantalla de Mediciones el Día 12/11/2025*..... 88

## Lista de Apéndices

<b>Apéndice A</b> <i>Sección del Código de Programación del Arduino UNO R4 Wifi</i> .....	82
<b>Apéndice B</b> <i>Sección del Código en Python para el Calculo de la Posición del Panel Según el Modelo de Machine Learning</i> .....	84
<b>Apéndice C</b> <i>Registro Fotográfico</i> .....	87
<b>Apéndice D</b> <i>Presupuesto del Seguidor Solar de 1200W</i> .....	89

## Introducción

La energía solar fotovoltaica se ha consolidado como una de las alternativas más prometedoras para la transición hacia fuentes de energía renovables, experimentando un crecimiento acelerado en los últimos años a nivel mundial (IEA, 2025). Sin embargo, uno de los principales desafíos para maximizar la eficiencia de los sistemas fotovoltaicos radica en optimizar la captación de radiación solar a lo largo del día. Los paneles solares estáticos, aunque representan la solución más económica y común, presentan una limitación fundamental: su orientación fija les impide mantener un ángulo óptimo respecto a la posición cambiante del sol, resultando en pérdidas significativas de energía, especialmente durante las horas de la mañana y la tarde.

Los sistemas de seguimiento solar han emergido como una solución tecnológica para abordar esta problemática, permitiendo que los paneles fotovoltaicos se orienten dinámicamente hacia el sol durante su trayectoria diurna. Diversos estudios han demostrado que los seguidores solares de doble eje pueden incrementar la captación energética entre un 30% y un 45% en comparación con instalaciones estáticas (Sadeghi et al., 2025), dependiendo de las condiciones geográficas y climáticas. No obstante, la implementación de estos sistemas ha enfrentado barreras importantes relacionadas con su costo inicial, complejidad de instalación y mantenimiento, así como con los métodos de control empleados para determinar la orientación óptima del panel.

La aparición de tecnologías de paneles solares bifaciales ha introducido una nueva dimensión en la optimización de sistemas fotovoltaicos. A diferencia de los paneles convencionales que captan radiación únicamente por su cara frontal, los paneles bifaciales pueden aprovechar tanto la radiación solar directa como la reflejada desde el suelo y el entorno

circundante a través de ambas caras. Esta característica puede incrementar la generación energética entre un 7.75% y un 15% adicional (Maniscalco et al., 2024), dependiendo del albedo superficial y las condiciones de instalación. Sin embargo, la optimización del seguimiento solar para paneles bifaciales presenta un desafío considerablemente más complejo que para paneles monofaciales, ya que la orientación óptima no depende únicamente de maximizar la incidencia directa del sol sobre la cara frontal, sino de encontrar un equilibrio que considere simultáneamente la captación en ambas caras del panel.

Tradicionalmente, los sistemas de seguimiento solar han utilizado dos enfoques principales: el seguimiento mediante sensores ópticos, que detectan directamente la posición del sol utilizando fotoresistores o sensores de luz, y el seguimiento astronómico, que calcula la posición solar basándose en coordenadas geográficas, fecha y hora mediante algoritmos matemáticos establecidos. Cada método presenta ventajas y limitaciones específicas. Los sensores ópticos son simples y directos, pero pueden verse afectados por condiciones climáticas adversas como nubosidad o contaminación. Por otro lado, el seguimiento astronómico ofrece precisión bajo cualquier condición atmosférica, aunque en el caso de paneles bifaciales, no considera la contribución de la radiación reflejada sobre la cara opuesta ni las variables ambientales locales que afectan la captación energética total del sistema (Rodríguez-Gallegos et al., 2020) (Santos de Araújo et al., 2024).

En años recientes, los avances en inteligencia artificial y aprendizaje automático han abierto nuevas posibilidades en el control de sistemas energéticos. Los algoritmos de machine learning, particularmente aquellos basados en árboles de decisión como Random Forest, han demostrado capacidad para modelar relaciones complejas entre múltiples variables y optimizar procesos de control de sistemas fotovoltaicos en tiempo real (A. R. Singh et al., 2025). Estos

métodos tienen el potencial de integrar información de múltiples fuentes, aprender de patrones históricos y adaptarse a condiciones cambiantes. En el contexto específico de paneles bifaciales, el machine learning podría resultar especialmente valioso al permitir que el sistema aprenda la orientación óptima considerando no solo la posición del sol, sino también las condiciones de irradiancia, albedo y otros factores ambientales que afectan simultáneamente la captación en ambas caras del panel.

El presente trabajo aborda esta problemática mediante el diseño y construcción de un prototipo de seguidor solar de doble eje para paneles bifaciales, desarrollado con componentes de fácil acceso y bajo costo, con el objetivo de democratizar esta tecnología y hacerla más accesible para aplicaciones en pequeña escala. Se implementaron dos estrategias de control diferentes: un método convencional basado en el cálculo de la posición astronómica del sol y un enfoque innovador utilizando un modelo de Random Forest entrenado para predecir la orientación óptima del panel bifacial considerando la captación energética total. El desempeño de ambos métodos fue evaluado y comparado en términos de precisión de seguimiento, eficiencia energética y aprovechamiento de la capacidad bifacial del panel. Los resultados de este estudio buscan no solo determinar cuál método de control resulta más efectivo para maximizar la generación energética en paneles bifaciales bajo diferentes condiciones operativas, sino también proporcionar una alternativa viable y replicable para la implementación de sistemas de seguimiento solar en contextos donde los costos y la simplicidad técnica son factores determinantes.

## Justificación

La implementación de sistemas de energía solar fotovoltaica enfrenta el desafío constante de maximizar la eficiencia energética para mejorar la viabilidad económica y acelerar la adopción de esta tecnología renovable. Si bien los paneles solares estáticos representan la opción más económica, su incapacidad para seguir la trayectoria solar resulta en pérdidas energéticas significativas de la energía potencialmente capturable. Los sistemas de seguimiento solar de doble eje han demostrado su capacidad para mitigar estas pérdidas (Kazem et al., 2024), pero su adopción masiva se ha visto limitada por costos elevados, complejidad técnica y la falta de soluciones accesibles para usuarios de pequeña y mediana escala.

La reciente introducción de paneles solares bifaciales en el mercado ha creado una oportunidad única para incrementar aún más la eficiencia de los sistemas fotovoltaicos, aprovechando tanto la radiación directa como la reflejada desde el entorno. Sin embargo, esta tecnología también ha introducido una complejidad adicional en los algoritmos de seguimiento solar, ya que la orientación óptima para un panel bifacial no necesariamente coincide con aquella que maximiza la incidencia directa del sol sobre la cara frontal. Los métodos tradicionales de seguimiento astronómico, diseñados originalmente para paneles monofaciales, no consideran explícitamente la contribución energética de la cara posterior ni las condiciones ambientales locales que afectan la radiación reflejada, lo que representa una limitación significativa para explotar todo el potencial de la tecnología bifacial.

El desarrollo de algoritmos de control basados en machine learning, específicamente Random Forest, ofrece una alternativa prometedora para abordar esta complejidad. A diferencia de los métodos astronómicos que se basan en modelos matemáticos predeterminados, los algoritmos de aprendizaje automático pueden aprender de datos de operación o modelados y

considerar múltiples variables simultáneamente, incluyendo patrones de irradiancia, condiciones de albedo, temperatura y otros factores que afectan la generación energética total de un panel bifacial. Esta capacidad de aprendizaje y adaptación podría traducirse en estrategias de seguimiento más eficientes y robustas, particularmente en entornos con condiciones variables o en instalaciones donde las características del terreno y el entorno influyen significativamente en la radiación reflejada.

Desde una perspectiva práctica, existe una necesidad de desarrollar soluciones de seguimiento solar que sean técnica y económicamente accesibles para un espectro más amplio de usuarios. Las comunidades rurales, pequeñas empresas, instituciones educativas y proyectos de electrificación descentralizada podrían beneficiarse enormemente de sistemas de seguimiento solar de bajo costo que no requieran expertise técnico especializado para su instalación y mantenimiento. El uso de componentes comerciales de fácil acceso y la implementación de algoritmos de control que puedan ejecutarse en hardware económico representa un paso importante hacia la democratización de esta tecnología.

La comparación directa entre el método de seguimiento astronómico tradicional y un enfoque basado en machine learning para paneles bifaciales constituye una contribución relevante al estado del conocimiento actual. Aunque existen numerosos estudios sobre seguimiento solar y trabajos recientes sobre la aplicación de inteligencia artificial en sistemas fotovoltaicos, la literatura científica carece de evaluaciones sistemáticas que comparen estos enfoques específicamente en el contexto de paneles bifaciales operando en sistemas de doble eje. Este proyecto puede proporcionar evidencia empírica sobre las ventajas y limitaciones de cada método, orientando futuras investigaciones y desarrollos tecnológicos en esta área.

Finalmente, este trabajo responde a la necesidad de generar conocimiento aplicable que pueda transferirse efectivamente al sector productivo y a la sociedad. El desarrollo de un prototipo funcional con documentación de su construcción y programación no solo genera resultados de investigación, sino que también produce un recurso replicable que puede ser adoptado, modificado y mejorado por otros. En un contexto global donde la transición energética es imperativa para enfrentar el cambio climático, cada innovación que contribuya a hacer más eficientes, accesibles y económicos los sistemas de energía solar representa un aporte significativo hacia un futuro energético más sostenible.

## **Objetivos**

### **Objetivo General**

Evaluar el desempeño energético de un sistema de seguimiento solar bifacial de doble eje de bajo costo para determinar la eficiencia comparativa entre algoritmos de control astronómicos y modelos de aprendizaje automático en condiciones meteorológicas reales.

### **Objetivos Específicos**

Desarrollar un prototipo de seguidor solar bifacial de doble eje y bajo costo para optimizar la captación de energía fotovoltaica en sistemas de generación a pequeña escala.

Comparar la eficacia de un algoritmo de control basado en cálculos astronómicos frente a uno basado en aprendizaje automático (Machine Learning) para determinar el método de mayor precisión en el seguimiento solar.

Sincronizar el sistema de control con variables meteorológicas en tiempo real para permitir el ajuste dinámico del posicionamiento angular según las condiciones atmosféricas locales.

Evaluar el rendimiento energético neto y la eficiencia de los métodos de seguimiento implementados para establecer la viabilidad técnica de cada estrategia bajo condiciones meteorológicas variables.

Determinar la factibilidad técnica y económica de escalar el sistema basado en aprendizaje automático para su potencial integración en plantas fotovoltaicas de gran envergadura.

## **Marco de Referencia**

El desarrollo de este proyecto se sustenta en un marco de referencia que integra los fundamentos conceptuales y las disposiciones normativas que orientan la tecnología solar en Colombia. El marco teórico aporta las bases científicas y técnicas necesarias para comprender y justificar el diseño del seguidor solar propuesto, mientras que el marco legal garantiza que su desarrollo se alinee con la regulación vigente en materia de energías renovables. Ambos componentes proporcionan el soporte esencial para la adecuada formulación y pertinencia del proyecto.

### **Marco Teórico**

Esta sección contiene información general con respecto a los seguidores solares, la radiación solar que alimenta a los paneles solares, el aprendizaje automático y su uso en el contexto de la temática del proyecto.

### ***Paneles Solares Bifaciales***

Las tecnologías fotovoltaicas bifaciales tienen la capacidad de incrementar la producción energética sin aumentar el área del módulo. A diferencia de los paneles monofaciales tradicionales, los módulos bifaciales pueden absorber fotones tanto por la cara frontal como por la posterior, lo que permite aprovechar simultáneamente la radiación directa, la radiación difusa y la luz reflejada por el entorno. Su principio de funcionamiento es similar al de una celda fotovoltaica convencional, pero la cara posterior incorpora un recubrimiento pasivado con propiedades antirreflejantes y un patrón de contactos metálicos delgados, semejantes a pequeñas líneas conductoras, que cumplen la misma función que los contactos frontales (Bora et al., 2025). Esta estructura incrementa la absorción de fotones y permite generar pares electrón hueco adicionales, los cuales contribuyen al flujo de corriente a través del circuito externo.

En términos constructivos, los módulos bifaciales se diferencian de los monofaciales principalmente por el uso de vidrio en ambas caras, en lugar de una lámina posterior opaca. Esta característica posibilita que parte de la radiación difusa y de la luz reflejada por el suelo u otras superficies, así como la luz que atraviesa los espacios entre celdas, pueda incidir en la cara posterior del panel. Como resultado, la irradiancia total aprovechada por el dispositivo aumenta y el módulo puede generar más energía que su equivalente monofacial, utilizando la misma cantidad de material semiconductor y sin requerir mayor espacio de instalación. Esto convierte a los módulos bifaciales en una opción altamente eficiente para sistemas solares avanzados, especialmente cuando se utilizan junto con seguidores solares de doble eje.

### ***Seguidores Solares***

La generación de energía solar fotovoltaica depende en gran medida del aprovechamiento de la radiación solar a lo largo del día. Para aumentar la eficiencia de los paneles solares, se han desarrollado dos configuraciones de instalación de seguimiento solar como alternativa a los sistemas de ángulo fijo: los de un solo eje y los de doble eje.

**Sistemas Fotovoltaicos de Ángulo Fijo.** En los sistemas de ángulo fijo, los paneles se instalan con una inclinación determinada según estudios de radiación solar para la ubicación específica. Estos permanecen inmóviles, lo que limita la captación de energía, ya que no se ajustan a la trayectoria del sol durante el día. Como consecuencia, su eficiencia es relativamente baja en comparación con los sistemas de seguimiento.


**Seguidores Solares de un Solo Eje.** Por otro lado, los sistemas de seguimiento solar de un solo eje permiten que los paneles se orienten dinámicamente siguiendo el movimiento del sol. Generalmente, se instalan con un eje norte-sur y se desplazan en dirección este-oeste, logrando así un mejor aprovechamiento de la radiación solar. Este tipo de sistema incrementa la

producción de energía entre un 25 % y 30 % en comparación con los sistemas de ángulo fijo (Alici et al., 2021).

**Seguidores Solares de Doble Eje.** Un seguidor solar de doble eje es un mecanismo que ajusta automáticamente la orientación de un panel solar en dos ejes: azimutal (vertical) y cenital (horizontal). Esto le permite seguir con precisión la trayectoria del sol a lo largo del día (de este a oeste) y durante las estaciones (de norte a sur), maximizando la captación de energía solar (Amelia et al., 2020). Los sistemas de doble eje, aunque más complejos y costosos, son más capaces de capturar energía que los seguidores de un solo eje, ya que pueden mantener los paneles perpendiculares a los rayos solares en todo momento, lo que optimiza la generación de energía hasta en un 40% más que los sistemas fijos (Alici et al., 2021).

### Figura 1

*Posicionamiento de un Seguidor Solar de Doble Eje Durante el Día*



*Nota.* Tres paneles solares orientados en posiciones diferentes según la ubicación horaria del Sol.

### ***Accionamiento de un Seguidor Solar***

Existen dos agrupaciones de mecanismos de seguimiento solar: Seguidores Solares Pasivos y Seguidores Solares Activos.

**Seguidores Solares Pasivos.** Los seguidores solares pasivos operan sin necesidad de energía externa o sistemas de control complejos, utilizando principios físicos para el movimiento de seguimiento. Estos sistemas aprovechan las diferencias de temperatura, presión, o las propiedades de materiales específicos para generar el movimiento de seguimiento de forma autónoma.

Entre los mecanismos pasivos se encuentran los (Kumba et al., 2024):

- **Sistemas Bimetálicos:** Emplean la expansión diferencial de metales con diferentes coeficientes de expansión térmica. La radiación solar calienta selectivamente el material bimetálico, generando una deformación que produce el movimiento de seguimiento.
- **Sistemas de Fluidos Termosensibles:** Utilizan la expansión volumétrica de fluidos (líquidos o gases) contenidos en cámaras selladas. El calentamiento diferencial del fluido genera provoca un desequilibrio que ocasiona el movimiento del panel hacia la posición de mayor insolación.
- **Sistemas de Materiales con Memoria de Forma:** Incorporan aleaciones que experimentan cambios dimensionales reversibles en respuesta a variaciones de temperatura, permitiendo el seguimiento solar sin actuadores externos.

Las principales ventajas de los seguidores pasivos son su simplicidad constructiva que reduce costos de manufactura e instalación, ausencia de consumo energético para el seguimiento, mantenimiento mínimo debido a la reducción de componentes móviles y electrónicos, y confiabilidad operativa elevada por la ausencia de sistemas de control susceptibles a fallas. Sin

embargo, los seguidores pasivos tienen limitaciones como la menor precisión de seguimiento y respuesta, la dificultad para implementar un seguimiento optimizado, y el poco rendimiento en lugares con bajas temperaturas (Sadeghi et al., 2025).

**Seguidores Solares Activos.** Los seguidores solares activos emplean sistemas de control electrónicos junto con motores, sensores y algoritmos que permiten una orientación más precisa hacia el sol. Estos dispositivos pueden configurarse en un eje o en dos ejes, logrando un ángulo de incidencia casi perpendicular a los rayos solares durante todo el día y todo el año. La arquitectura depende del tipo sistema pero suelen incluir una unidad de control central (microcontrolador o PLC), sensores de posición solar, motores, y sistemas de retroalimentación para verificar el posicionamiento.

Los sistemas activos ofrecen precisión de seguimiento superior, capacidad para implementar estrategias de seguimiento optimizadas según condiciones meteorológicas, flexibilidad para manejar múltiples configuraciones de paneles, y posibilidad de integración con sistemas de monitoreo y control remoto.

Las limitaciones de los sistemas activos incluyen mayor complejidad del sistema que incrementa los costos de instalación y mantenimiento, consumo energético continuo para alimentar motores y sistemas de control, susceptibilidad a fallas en componentes electrónicos y mecánicos, y necesidad de mantenimiento preventivo regular.

### ***Radiación Solar***

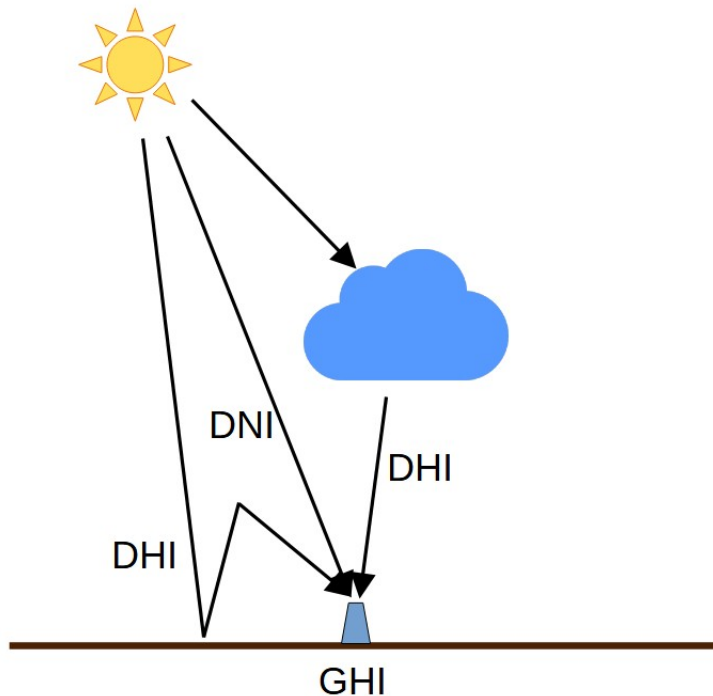
La radiación solar es la energía electromagnética emitida por el Sol que se propaga a través del espacio y constituye la fuente primaria de energía para la mayoría de los procesos naturales en la Tierra, incluyendo la generación de energía fotovoltaica. Sin embargo, esta radiación experimenta modificaciones durante su tránsito a través de la atmósfera terrestre

debido a procesos de absorción, dispersión y reflexión (Marsh & Kaufman, 2013), lo que da lugar a diferentes componentes que deben ser considerados en el análisis y diseño de instalaciones solares (Figura 2).

**Irradiancia Horizontal Global (GHI).** La Irradiancia Horizontal Global (Global Horizontal Irradiance, GHI) corresponde a la cantidad total de energía solar que incide sobre una superficie horizontal en la Tierra. Este parámetro incluye tanto la radiación directa proveniente del sol como la radiación difusa resultante de la dispersión atmosférica (Vignola, 2019). El GHI se expresa en unidades de energía por unidad de área ( $W/m^2$ ) y es uno de los indicadores más utilizados para dimensionar y evaluar el potencial de generación de sistemas fotovoltaicos fijos.

**Irradiancia Horizontal Difusa (DHI).** La Irradiancia Horizontal Difusa (Diffuse Horizontal Irradiance, DHI) corresponde a la radiación solar que ha sido dispersada por la atmósfera antes de alcanzar la superficie terrestre. Esta dispersión ocurre debido a la interacción con moléculas de gases atmosféricos, aerosoles y partículas de mayor tamaño, incluyendo vapor de agua y contaminantes, además de la reflexión ocurrida por las nubes, la superficie terrestre y la atmósfera (Myers, 2013).

**Irradiancia Normal Directa (DNI).** La Irradiancia Directa Normal (Direct Normal Irradiance, DNI) es la porción de radiación solar que llega de manera directa desde el sol y medida sobre una superficie que siempre está perpendicular a los rayos solares (Vignola, 2019). La DNI es crítico en tecnologías de concentración solar y en sistemas de seguidores solares, ya que estos deben orientarse continuamente hacia el sol para maximizar su captación.

**Figura 2***Componentes de la Radiación Solar*

*Nota.* Ilustración de los tipos de radiación solar medidos desde la superficie terrestre una vez atraviesa la atmósfera.

***Aprendizaje Automático***

El aprendizaje automático o machine learning (ML) es una rama de la inteligencia artificial que se centra en el desarrollo de algoritmos capaces de aprender patrones a partir de datos y mejorar su desempeño sin ser programados explícitamente, imitando la capacidad de aprender de las personas mediante ejemplos (Carlos Véliz, 2020). Entre sus principales paradigmas se encuentran el aprendizaje supervisado, no supervisado y por refuerzo, cada uno de los cuales permite abordar distintos problemas de predicción, clasificación y optimización en sistemas dinámicos.

Este proyecto se concentrará en el uso de modelos de aprendizaje supervisados, los cuales utilizan conjuntos de datos etiquetados para entrenar modelos que pueden predecir resultados para nuevas entradas. Incluye técnicas como regresión lineal, árboles de regresión, redes neuronales y máquinas de vectores de soporte. Estos se pueden dividir en dos grandes grupos de métodos supervisados: Algoritmos de Regresión, que se utilizan para predecir atributos numéricos; y Algoritmos de Clasificación, empleados para predecir atributos categóricos (Rodríguez Muinos et al., 2022).

**Bosque Aleatorio o Random Forest.** Random Forest es un método de aprendizaje automático supervisado basado en el principio de los ensemble methods (Kumar Tyagi et al., 2024). Su objetivo principal es mejorar la capacidad de generalización de un modelo combinando múltiples árboles de decisión que trabajan en conjunto para la predicción. En lugar de depender de un único árbol que podría sobreajustarse (overfitting) a los datos de entrenamiento, el algoritmo crea muchos árboles independientes y luego promedia o vota sus resultados para obtener la predicción final.

Un árbol de decisión es una estructura jerárquica donde, partiendo de un nodo raíz, se realizan particiones sucesivas de los datos en función de ciertos atributos, hasta llegar a hojas que representan las categorías (en clasificación) o valores numéricos (en regresión) (Carlos Véliz, 2020). Aunque los árboles son intuitivos y fáciles de interpretar, tienden a tener alta varianza, inestabilidad y requieren muchos datos.

Para generar los múltiples árboles, Random Forest utiliza la técnica de bagging (Bootstrap Aggregating). Esto implica tomar muestras aleatorias (con reemplazo) del conjunto de datos de entrenamiento, generando subconjuntos de datos para entrenar cada árbol de manera

independiente (Menoyo Ros et al., 2021). Esto diversifica los árboles y ayuda a reducir la varianza del modelo.

Además del muestreo de datos, en cada nodo de un árbol de la Random Forest se escoge aleatoriamente un subconjunto de atributos para seleccionar el mejor punto de división (split). De esta manera se evita que todos los árboles se centren en las mismas variables, promoviendo la diversidad en las estructuras de los árboles.

Tras entrenar todos los árboles, el modelo combina los resultados individuales a través de un proceso de votación (en el caso de clasificación) o mediante el promedio de los valores predichos (en el caso de regresión). Esta agregación de las predicciones contribuye a mejorar la estabilidad y exactitud del sistema respecto a un único árbol de decisión.

Random Forest suele proporcionar una alta precisión de predicción debido a que combina un gran número de árboles de decisión, lo que reduce la variabilidad y permite un mejor desempeño en problemas de clasificación y regresión. Además, al promediar múltiples árboles, el método se vuelve robusto frente al sobreajuste, manteniendo un buen equilibrio entre sesgo y varianza. Por otra parte, es capaz de manejar sin dificultad un gran número de características (atributos), lo que resulta útil en escenarios con información de alta dimensionalidad.

Sin embargo, al tratarse de un ensemble de árboles, la interpretabilidad del modelo se ve reducida en comparación con un único árbol de decisión, ya que el proceso de toma de decisiones se distribuye entre muchos árboles diferentes. Asimismo, entrenar un gran número de árboles puede requerir más recursos computacionales, tanto en términos de tiempo de cómputo como de memoria, lo cual podría ser una limitación en sistemas con recursos muy restringidos.

**Minimum Redundancy Maximum Relevance (mRMR) para Random Forest.** El método Minimum Redundancy Maximum Relevance (mRMR) es una estrategia de selección de

características utilizada en sistemas de aprendizaje automático con altos volúmenes de variables. Su objetivo es identificar un subconjunto óptimo de atributos que aporten la mayor cantidad de información relevante con respecto a la variable objetivo, minimizando al mismo tiempo la redundancia entre ellos (Harar, 2022). Este enfoque permite reducir la dimensionalidad del conjunto de datos sin sacrificar capacidad predictiva, lo que resulta útil en modelos basados en árboles como Random Forest, donde la presencia de atributos altamente correlacionados puede afectar la interpretabilidad y generar sobrecostos computacionales.

En mRMR, la relevancia se mide comúnmente mediante métricas de dependencia estadística, como la información mutua, que cuantifica la cantidad de información compartida entre una característica y la variable de salida. De manera complementaria, la redundancia evalúa el grado de similitud o dependencia entre las características ya seleccionadas. Un buen conjunto de variables debe estar altamente correlacionado con la salida del modelo (máxima relevancia) y aportar información distinta entre sí (mínima redundancia).

Cuando mRMR se combina con Random Forest, se genera un proceso de selección que aprovecha las ventajas de ambos enfoques. Random Forest, al basarse en múltiples árboles de decisión construidos mediante muestreo aleatorio de características y observaciones, es capaz de estimar de forma robusta la importancia relativa de cada variable. Sin embargo, esta importancia puede verse distorsionada cuando existen atributos redundantes o altamente correlacionados, ya que el modelo tiende a repartir la importancia entre ellos. La aplicación de mRMR antes del entrenamiento permite mitigar este efecto, favoreciendo un conjunto de variables más informativo y reduciendo la competencia entre predictores equivalentes (K. K. R et al., 2024).

## **Marco Legal**

El desarrollo de sistemas fotovoltaicos y, en particular, de seguidores solares en Colombia se enmarca dentro de un conjunto de leyes, normas técnicas y regulaciones nacionales e internacionales que buscan garantizar la seguridad eléctrica, la eficiencia energética y la calidad de los equipos empleados en la conversión de energía solar.

### ***Normativa Colombiana Aplicable***

A continuación se presentan algunas de las normas colombianas más relevantes que aplican a proyectos fotovoltaicos de pequeña y gran escala.

**Ley 1715 de 2014.** La Ley 1715 promueve el desarrollo y la integración de las Fuentes No Convencionales de Energía (FNCE), específicamente las renovables, dentro del sistema energético nacional. Esta ley constituye el marco general que habilita y fomenta el uso de tecnologías solares en Colombia. En su Artículo 1, establece como objetivo facilitar la incorporación de estas fuentes al mercado eléctrico, su adopción en zonas no interconectadas y su aplicación en servicios públicos, alumbrado y otros usos energéticos. Asimismo, promueve la gestión eficiente de la energía, el uso de sistemas de almacenamiento y la implementación de medición inteligente, aspectos alineados con el diseño de sistemas solares avanzados basados en control automatizado y análisis de datos.

El seguidor solar desarrollado en este trabajo, aunque de carácter experimental, se integra conceptualmente dentro de los esfuerzos que la Ley 1715 impulsa: sistemas capaces de incrementar la eficiencia de captación solar, promover la reducción de emisiones y contribuir al uso racional de la energía.

**Reglamento Técnico de Instalaciones Eléctricas (RETIE).** El RETIE establece los requisitos mínimos para garantizar la seguridad de las instalaciones eléctricas en Colombia. Esto

incluye protección contra descargas eléctricas, fallas a tierra, sobrecorrientes, compatibilidad electromagnética, puesta a tierra y certificación de productos y componentes eléctricos (Ministerio de Minas y Energía, 2024).

Aunque el prototipo desarrollado en este documento opera a baja potencia y voltaje (menos de 24V en corriente continua) y en un entorno controlado, para cualquier proyecto que se desarrolle en el territorio nacional de un seguidor solar con voltajes superiores, el diseño eléctrico, la disposición de cableado, las protecciones, y la puesta a tierra deben ser coherentes con lo establecido por el RETIE para garantizar condiciones seguras durante la operación.

**Norma Técnica Colombiana NTC 2050 o Código Eléctrico Colombiano.** La NTC 2050, basada en el National Electrical Code (NEC) de Estados Unidos (*Código eléctrico colombiano*, 2020), regula el diseño, construcción y mantenimiento de instalaciones eléctricas. Para sistemas fotovoltaicos, define parámetros de seguridad, conducción, protecciones, calibre de conductores, canalizaciones y dispositivos de desconexión.

En el caso de seguidores solares, esta norma orienta la selección de componentes eléctricos tales como motores, controladores, protecciones y cableado, asegurando que la configuración cumpla con lineamientos mínimos de seguridad y buenas prácticas de instalación.

**Regulación sobre Autogeneración y Generación Distribuida.** Dado que los sistemas fotovoltaicos con seguidores solares pueden integrarse a proyectos de autogeneración, resultan relevantes las siguientes resoluciones:

- Resolución UPME 281 de 2015: define que la autogeneración a pequeña escala tiene un límite máximo de potencia instalada de 1 MW, aplicable al dimensionamiento de sistemas FV conectados al Sistema Interconectado Nacional (SIN).
- Resolución CREG 24 de 2015: establece las condiciones para la autogeneración a

gran escala en el sistema interconectado nacional.

Si bien el sistema desarrollado en este trabajo no supera estos umbrales y se implementa con fines de investigación y validación experimental, el diseño de seguidores solares en Colombia debe respetar los principios técnicos que estas regulaciones establecen para sistemas fotovoltaicos conectados o con potencial de conexión a la red.

### ***Estándares Internacionales para Seguidores Solares***

Aunque en Colombia no existe una norma estrictamente dedicada a la calificación de seguidores solares, a nivel internacional destacan dos estándares ampliamente aceptados que establecen requisitos de diseño, operación, seguridad y confiabilidad. Estos estándares sirven como referencia técnica para el diseño y evaluación de plataformas de seguimiento solar como la desarrollada en este proyecto.

**IEC 62817 – “Photovoltaic Systems – Design Qualification of Solar Trackers”.** La norma IEC 62817 constituye el estándar internacional de referencia para la calificación del diseño de seguidores solares, tal como se describe en el documento técnico correspondiente (International Electrotechnical Commission, 2017). Su propósito principal es asegurar que los parámetros de desempeño reportados por los fabricantes sean evaluados mediante procedimientos uniformes, verificables y reproducibles.

Esta norma abarca:

- Definiciones y taxonomía de seguidores solares, incluyendo seguidores de un eje, dos ejes, y sistemas diseñados tanto para módulos fotovoltaicos convencionales (PV) como para tecnologías fotovoltaicas de concentración (CPV).
- Requisitos mecánicos y estructurales, como rigidez, backlash, tolerancias en ejes, consumo energético y características del sistema de accionamiento.

- Ensayos funcionales, tales como validación de límites de seguimiento, operación manual, recuperación tras fallos, procedimientos de stow (posición de seguridad), y respuesta ante interrupciones de energía.
- Ensayos ambientales y mecánicos, incluyendo ciclos térmicos, vibración, impactos, pruebas de viento, cargas estáticas, humedad y radiación UV.
- Caracterización de precisión del seguimiento, mediciones de error de apuntado, organización de los datos en intervalos o categorías (binning) basados en la velocidad del viento, y métodos estandarizados de cálculo.

Aunque el prototipo desarrollado no se somete a todas las pruebas de certificación de la IEC 62817, la norma ofrece criterios esenciales para evaluar la calidad del diseño, la robustez mecánica y la precisión de los algoritmos de seguimiento. En este proyecto, dichos lineamientos sirvieron como referencia conceptual para contrastar el desempeño entre el algoritmo astronómico y el modelo de aprendizaje automático.

**Certificación UL 3703 (Estados Unidos).** La especificación UL 3703 de la empresa UL Solutions establece los requisitos de seguridad para seguidores solares, centrándose en aspectos eléctricos y mecánicos esenciales para cumplir con el National Electrical Code (NFPA 70) en instalaciones fotovoltaicas (UL Solutions, 2025) (Bushong, 2016).

Esta certificación evalúa

- Sistemas de montaje y fijación.
- Integridad mecánica y protección contra el fallo estructural.
- Correcta interconexión eléctrica de todas las partes metálicas del seguidor y los módulos (bonding) y su adecuada conexión a tierra (grounding), con el fin de garantizar la seguridad eléctrica del sistema y la protección frente a fallas o descargas.

- Procedimientos de instalación y seguridad operativa.
- Compatibilidad con los requisitos de la norma UL 2703 para estructuras y sistemas de montaje fotovoltaico.

Aunque es una certificación especialmente relevante para proyectos comerciales y de gran tamaño para servicios públicos en Estados Unidos, constituye una referencia de buenas prácticas para el diseño seguro y confiable de seguidores solares en cualquier país.

**Consideraciones Éticas y de Uso de Datos.** Algunas de las fuentes de datos que se plantearon usar para el modelo de aprendizaje automático desarrollado en este proyecto son:

- Open-Meteo: plataforma abierta de pronósticos meteorológicos (Zippenfenig, 2024).
- PVLIB (Python): librería para modelado fotovoltaico con acceso a datos astronómicos y meteorológicos (Anderson et al., 2023).
- NSRDB (NREL): base de datos de radiación solar de alta resolución, de acceso libre para fines académicos y de investigación.

Estas plataformas permiten el uso de la información con fines investigativos, siempre que se cite adecuadamente la fuente y se respeten los términos de uso establecidos por cada proveedor.

El diseño y la construcción de un seguidor solar desarrollado debe apoyarse en un marco legal sólido que abarca leyes colombianas, normas técnicas nacionales y estándares internacionales de diseño y seguridad. El cumplimiento conceptual de estas disposiciones permite garantizar que el sistema no solo sea funcional desde el punto de vista técnico, sino que se ajuste a los principios de seguridad, confiabilidad y eficiencia que rigen las tecnologías solares modernas.

## Antecedentes

En los últimos años Colombia ha mostrado un creciente interés por la autogeneración y los proyectos solares, tanto a pequeña escala como en desarrollos de mayor envergadura. Informes de prensa regional señalan un aumento en las solicitudes y trámites relacionados con proyectos de autogeneración en la región Caribe, lo que refleja una mayor participación de usuarios y empresas en la adopción de sistemas de generación distribuida (López Ortega, 2025).

El mercado de seguidores solares en Latinoamérica y en Colombia en particular ha experimentado actividad comercial significativa ya que fabricantes y proveedores internacionales han cerrado pedidos importantes y están ampliando su oferta para la región. Por ejemplo, se reportó un pedido de un sistema de seguidores inteligentes por 108 MW para Colombia gestionado por TrinaTracker (Energía Estratégica, 2023), y distintos fabricantes como Arctech han diversificado sus líneas de trackers flexibles dirigidas a proyectos latinoamericanos (Energía Estratégica, 2025). Estas operaciones evidencian la demanda por soluciones de seguimiento que optimicen la producción en plantas fotovoltaicas.

En cuanto a proyectos de plantas solares con seguidores, en el oriente del país destaca el Parque Solar Bosque de Los Llanos (departamento del Meta), donde se instalaron alrededor de 2.250 seguidores de la serie Vanguard de TrinaTracker, configurados como seguidores de un eje horizontal para maximizar la captación anual de radiación directa (Energía Estratégica, 2021). Este tipo de solución combina módulos bifaciales de alta potencia con trackers para reducir el costo nivelado de energía y aumentar la producción frente a estructuras fijas.

Además, la dinámica regulatoria y ambiental avanza al ritmo de los proyectos puesto que se han concedido licencias ambientales relevantes para parques solares próximos a decenas de megavatios bajo nuevos regímenes de evaluación, lo que facilita la ejecución de proyectos de

gran tamaño (Ini, 2025). Al mismo tiempo, la entrada de fabricantes extranjeros especializados en seguidores al mercado latinoamericano muestra la internacionalización de la oferta tecnológica y el interés por instalar sistemas más eficientes. Tendencias conjuntas como el crecimiento de la autogeneración, pedidos de seguidores a gran escala, diversificación de productos y permisos ambientales para proyectos importantes, configuran un contexto nacional y regional favorable para la investigación aplicada en seguimiento solar y para soluciones de bajo costo que puedan adaptarse a distintos escalones de mercado.

Por otro lado, empresas nacionales han comenzado a desarrollar tecnología de seguimiento solar adaptada a las condiciones locales del país. Zentrack, compañía liderada por ingenieros colombianos y originada como proyecto de investigación universitaria en 2017, desarrolló el primer seguidor solar diseñado específicamente para Colombia, logrando incrementos de generación energética entre 18% y 25% comparado con estructuras fijas (Defelipe Díaz, 2025). La innovación obtuvo patente de modelo de utilidad por incorporar un sistema de autolimpieza activado por detección de lluvia, característica que reduce costos de mantenimiento y optimiza la captación en condiciones tropicales. Aunque el costo inicial de estos sistemas supera al de estructuras fijas, el incremento neto en generación energética puede justificar la inversión mediante mayor rentabilidad a largo plazo y mejor aprovechamiento del recurso solar disponible.

Zentrack ha expandido operaciones hacia mercados regionales como Brasil y Chile, aprovechando ventajas competitivas en flexibilidad y adaptabilidad para plantas solares pequeñas y medianas. Su desarrollo continuo incluye integración de inteligencia artificial, estaciones meteorológicas inteligentes y algoritmos avanzados para optimización predictiva de generación, señalando la evolución hacia sistemas más autónomos e inteligentes.

## Estado del Arte

El estudio de Santos de Araújo et al. (2024) propone un algoritmo de inteligencia artificial para seguidores solares de un eje en plantas fotovoltaicas bifaciales, donde se aprovecha tanto la radiación directa como la difusa. Mediante modelos que tienen en cuenta la posición del Sol, la geometría de la planta (distancia entre filas, albedo, etc.) y variables climáticas (radiación global, difusa, directa, nubosidad), se determina el ángulo óptimo de los paneles para cada momento del día. Comparado con el algoritmo comercial estándar, la solución basada en IA logró incrementos de generación, especialmente en días nublados, con ganancias de hasta un 7–8%, y un promedio global cercano al 1,2% en pruebas de campo reales.

La contribución principal del trabajo de Santos de Araújo et al. (2024) radica en combinar el aprovechamiento de la radiación difusa con mejoras en el backtracking (evitando sombras entre paneles), lo que hace que el sistema sea efectivo tanto en días soleados como en días con alta variabilidad meteorológica. El algoritmo se validó en una planta real en Brasil y se integró fácilmente en la infraestructura de seguidores, lo que demostró su factibilidad y potencial para maximizar la producción energética de grandes plantas fotovoltaicas.

Con el avance del aprendizaje automático, diversas técnicas han sido aplicadas para mejorar la precisión de los modelos térmicos de módulos fotovoltaicos. Entre ellas, la regresión lineal múltiple y los modelos basados en redes neuronales artificiales (ANN) han mostrado resultados prometedores, alcanzando errores absolutos inferiores a 2 °C en algunos casos (Lara-Vargas et al., 2025). No obstante, varios estudios mencionados en el artículo de Lara-Vargas et al. señalan limitaciones importantes: las ANN se comportan como cajas negras, lo cual dificulta la interpretación física del modelo y requieren un proceso de entrenamiento intensivo que incluye ajuste de hiperparámetros, selección de arquitectura y grandes volúmenes de datos.

En este contexto, el uso de regresión simbólica surge como una alternativa atractiva al ofrecer un equilibrio entre precisión, interpretabilidad y eficiencia computacional. El artículo de Lara-Vargas et al. propone un modelo basado en algoritmos genéticos capaz de descubrir expresiones matemáticas explícitas que relacionan radiación, temperatura ambiente y temperatura de módulo sin imponer una estructura funcional previa. A diferencia de los métodos empíricos clásicos, la regresión simbólica capta relaciones no lineales mediante términos trigonométricos y raíces, y a diferencia de las ANN, produce ecuaciones transparentes y fácilmente interpretables. Los resultados reportados muestran un desempeño superior a modelos convencionales y ML, con RMSE de 4.05 °C,  $R^2$  de 0.91 y MAE de 2.25 °C usando datos reales de una planta bifacial con seguidores de un eje en clima tropical, lo que evidencia su potencial para aplicaciones de optimización energética y operación en tiempo real.

El trabajo de Al-Muswe et al. (2022) presenta un sistema de seguimiento solar de dos ejes que emplea un algoritmo optimizado basado en aprendizaje profundo (Deep Learning o DL) para determinar la mejor orientación del panel en cada momento del día. En lugar de depender de métodos tradicionales (por ejemplo, sensores LDR), el método propuesto recurre a una red neuronal recurrente (RNN) con celdas Long Short Term Memory (LSTM), entrenada con datos históricos de posición solar y generación de potencia para predecir los ángulos de inclinación (horizontal y vertical) que maximizan la captación de radiación.

La arquitectura se implementó en un prototipo que integra un Arduino Mega 2560, módulos para medición de corriente y voltaje, GPS (para localizar y sincronizar la hora solar) y motores para mover el panel en dos ejes. Mediante un proceso de escaneo inicial y el uso de un optimizador tipo "Adam", la red LSTM aprende a estimar el ángulo que brinda mayor potencia a lo largo del día, superando en precisión a modelos de redes neuronales estándar. El estudio

demonstró que esta estrategia reduce el error de predicción y aumenta la generación energética respecto a un panel fijo y a modelos de RNN sin optimización, evidenciando el potencial de la inteligencia artificial para mejorar la eficiencia de los sistemas fotovoltaicos.

El aprendizaje profundo ha demostrado un potencial sobresaliente para abordar tareas complejas dentro del seguimiento solar, tales como la predicción de radiación, el modelado del movimiento solar y la optimización del ángulo de los paneles (Phiri et al., 2023). En el artículo de revisión de Phiri et al. (2023) se expone que diversos estudios han empleado redes neuronales convolucionales, recurrentes y modelos híbridos para incrementar la precisión del seguimiento y, por extensión, la eficiencia energética de los sistemas solares. En particular, los modelos híbridos basados en arquitecturas como Adaptive Neuro-Fuzzy Inference System (ANFIS) y combinaciones de LSTM con técnicas de extracción de características, han sido los más utilizados debido a su capacidad de capturar relaciones no lineales y patrones temporales en los datos.

A pesar de estos avances, la literatura muestra una alta heterogeneidad en las fuentes de datos, técnicas de preprocesamiento y métricas de evaluación utilizadas. Esto evidencia la ausencia de un marco estandarizado para el desarrollo y la validación de modelos DL en sistemas de seguimiento solar. Además, persisten desafíos relevantes como la disponibilidad de datos confiables, la integración de información meteorológica, la necesidad de mejorar los métodos de normalización y el diseño de estrategias de ingeniería de características más robustas. Por ello, las investigaciones actuales apuntan hacia soluciones que combinen modelos profundos con técnicas de optimización, extracción multiescala de características y datos multifuente para maximizar la precisión y la adaptabilidad de los sistemas de seguimiento (Phiri et al., 2023).

## **Metodología**

La metodología empleada para el desarrollo de este proyecto corresponde a una investigación aplicada de enfoque cuantitativo experimental, dado que se centra en el diseño, construcción y evaluación comparativa de un sistema físico mediante la medición sistemática de variables técnicas. Se implementa un enfoque experimental controlado donde se comparan dos tratamientos distintos (algoritmo astronómico y aprendizaje automático) aplicados al mismo sistema de seguimiento solar, midiendo variables como generación energética y ángulos de posicionamiento bajo condiciones meteorológicas cambiantes.

La investigación aplicada tiene como objetivo generar conocimiento orientado a resolver problemas concretos que requieren solución inmediata mediante la aplicación de principios científicos (Baena Paz, 2017), mientras que el diseño experimental permite establecer relaciones causales entre variables y comparar el desempeño de diferentes métodos bajo condiciones controladas (Lerma Gonzalez, 2016). La metodología se estructuró en fases secuenciales que abarcan el diseño mecatrónico, la implementación de algoritmos de control, la integración de datos meteorológicos, la experimentación con mediciones continuas y el análisis estadístico comparativo de resultados, permitiendo obtener conclusiones fundamentadas sobre la efectividad de cada estrategia de seguimiento.

### **Planteamiento y Diseño**

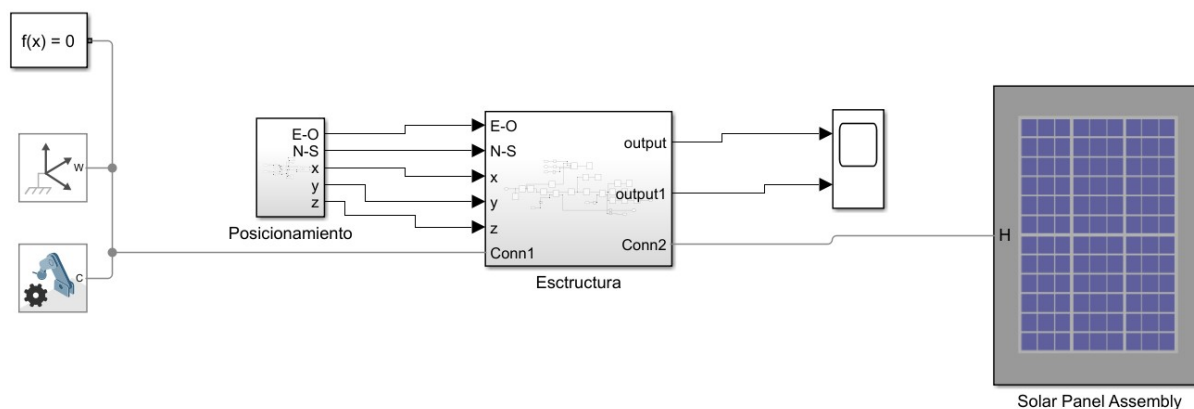
En esta primera etapa, se definieron los requisitos del prototipo y el plan de medición. Se seleccionaron los componentes, decidiendo las especificaciones del panel solar, los sensores de corriente y voltaje, sensores de posicionamiento, los actuadores, batería, control de carga, así como la plataforma de cómputo y control. Adicionalmente, se diseñó la arquitectura general del sistema, especificando la forma en que se integraron los módulos de medición, control, modelado

e inferencia, además de los cálculos con la biblioteca PVLIB de Python. Todo esto teniendo en cuenta que el proyecto se desarrolló en la ciudad de Cartagena de Indias y que el seguidor solar debe funcionar al aire libre en época de lluvia; por lo que sus componentes tienen que soportar la exposición al agua, el polvo y las altas temperaturas de la ciudad. Además, el espacio disponible para realizar la instalación no es amplio por lo que el panel no debe ser de gran tamaño.

La verificación preliminar del algoritmo de control fue hecha en Simulink de MATLAB, el cual ofrece la posibilidad de una modelación visual del sistema antes de su implementación. Para ello se usaron las herramientas Simscape Multibody y Simscape Electrical. La simulación se realizó para un día de prueba cada 10 minutos durante las horas de luz solar y su esquema general es mostrado en la Figura 3. La explicación más detallada del algoritmo y lo que se obtuvo se muestra en la sección de Análisis de Resultados.

### Figura 3

#### *Esquema General de la Simulación del Control del Seguidor Solar en Simulink*



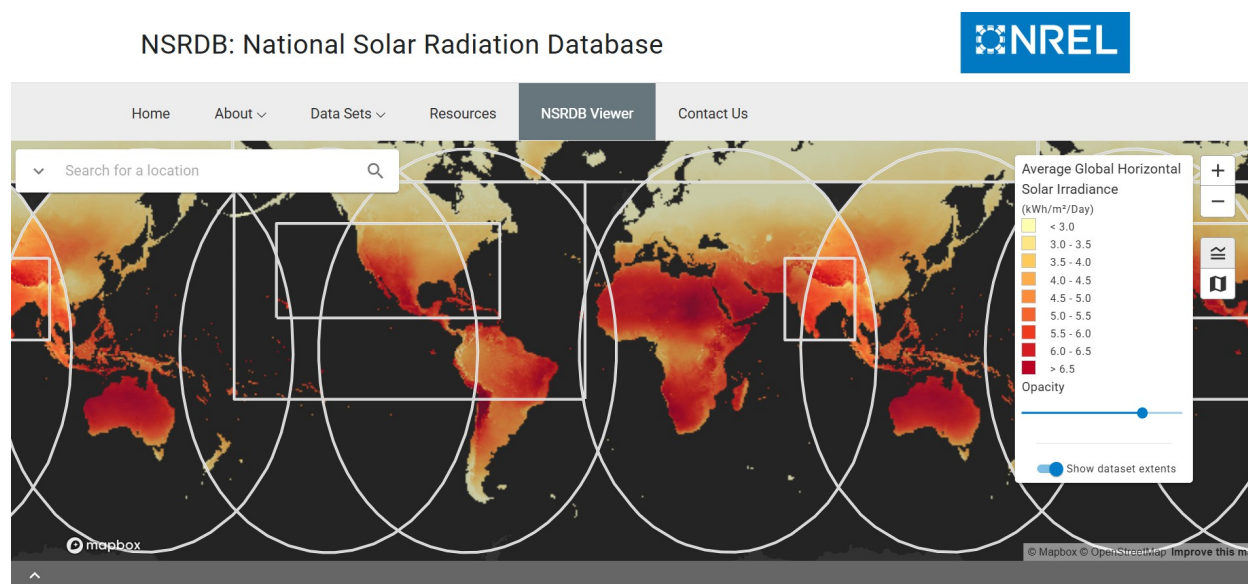
*Nota.* Modelo de la simulación en Simulink del control del seguidor solar, que contiene el algoritmo de posicionamiento, la estructura y el panel solar.

## Adquisición y Preparación de Datos para el Modelo

Los datos meteorológicos e irradiancia solar necesarios para entrenar el modelo de Machine Learning se obtuvieron de la base de datos National Solar Radiation Database (NSRDB) del National Renewable Energy Laboratory (NREL) (Figura 4). La serie de datos abarca el periodo 2018-2024 cada 10 minutos e incluye las variables DNI, DHI, GHI, dirección y velocidad del viento a 10 m de altura, presión superficial, temperatura, humedad relativa y albedo. De estas variables, la velocidad del viento se descartó puesto que tanto la base de datos del NSRDB como la base de datos del IDEAM están incompletas para el año 2024.

### Figura 4

*Visor de la Base de Datos NSRDB del NREL*



*Nota.* Captura de pantalla del visor del NSRDB desde donde se seleccionan los datos de interés según la ubicación geográfica. <https://nsrdb.nrel.gov/data-viewer>.

La posición astronómica del sol se obtuvo con el modelo NREL SPA que se encuentra dentro de PVLIB Python. Y finalmente, la posición óptima del panel solar que se usa como

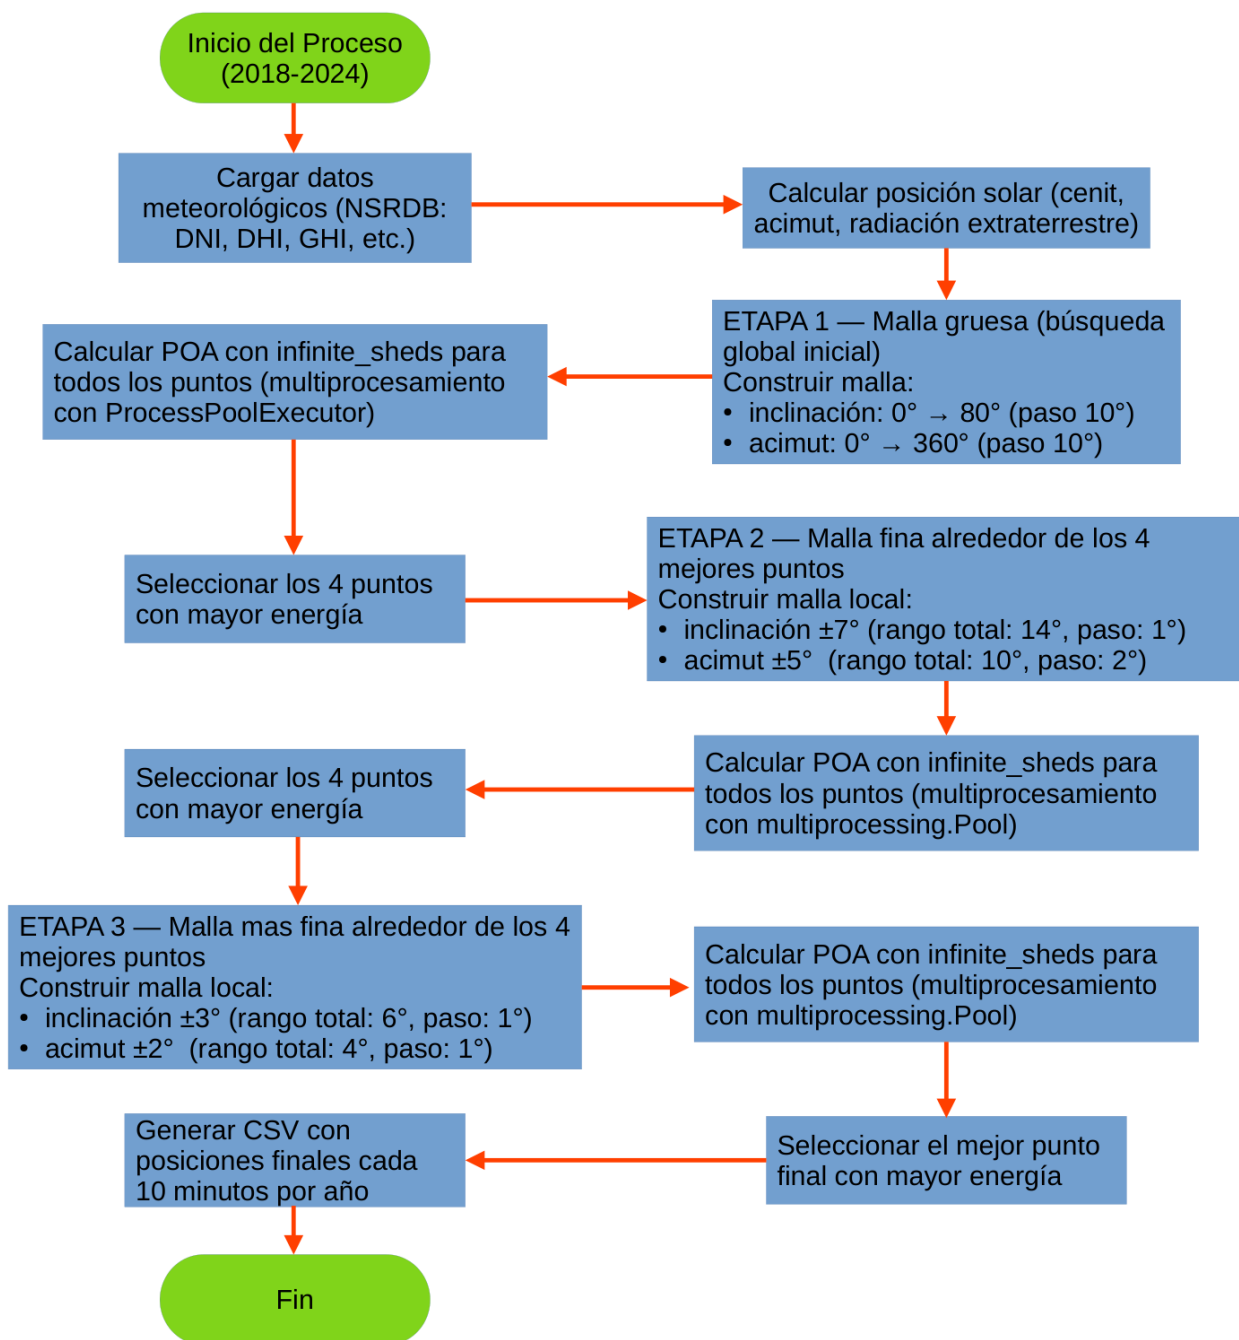
variable objetivo para el modelo de Random Forest se determinó mediante el algoritmo “infinite sheds” para panel bifacial, que también se encuentra dentro de PVLIB.

El algoritmo implementado en Python para obtener las variables objetivos consistió en crear mallas de posiciones con resolución variable que disminuye hasta encontrar la posición que genera mayor cantidad de energía, esto con el fin de reducir el tiempo de computo. También se habilitó la ejecución paralela del código. El diagrama de flujo que muestra el proceso completo se observa en la Figura 5.

### **Desarrollo y Entrenamiento del Modelo**

A cada parámetro de ubicación (Acimut e Inclinación) se le desarrolló un modelo independiente, teniendo en cuenta que sus valores no necesariamente coinciden con el valor de acimut y cenit solares. Siendo el Acimut el ángulo medido desde el norte geográfico en sentido horario, y la Inclinación el ángulo medido desde la normal terrestre hacia el suelo. Dichas variables son los objetivos de cada modelo, y los valores de entrenamiento, validación y prueba se obtuvieron separando la serie de datos en 70%, 20% y 10%, respectivamente.

Las variables más relevantes se determinaron para cada modelo a través del método minimum Redundancy - Maximum Relevance (mRMR) de regresión. El desarrollo de los modelos siguió un enfoque iterativo, comenzando con la evaluación comparativa de varios entrenamientos. Se evaluó el rendimiento mediante métricas como el Root Mean Square Error (RMSE) o el Mean Absolute Error (MAE). A medida que se obtuvieron los resultados, se ajustaron iterativamente tanto las variables de entrada como la configuración de los modelos para alcanzar el mejor desempeño posible evitando el sobre entrenamiento.

**Figura 5***Paso a Paso para Calcular las Posiciones Objetivo del Entrenamiento*

*Nota.* Algoritmo implementado en Python para obtener las posiciones que se usaron como objetivo en el entrenamiento del modelo de Random Forest.

## **Implementación en Hardware y Control en Tiempo Real**

El modelo entrenado se transfirió a un dispositivo capaz de ejecutar Python, que para efectos de la etapa de mediciones se optó por un computador portátil que ejecuta el código y le comunica las predicciones a una tarjeta Arduino UNO R4 Wifi para el control de los motores y lectura de sensores, ambos dispositivos conectados por puerto serial. Sin embargo, para disminuir la cantidad de dispositivos y dejar operando permanentemente el sistema luego de las mediciones, se usó una Raspberry Pi 5 de 8Gb de memoria RAM que tiene la capacidad de controlar los motores, leer los sensores, ejecutar el código de Python y cuenta con conectividad wifi.

En esta etapa también se desarrolló el software de control en tiempo real, de manera que, con base en la predicción del modelo, el panel se ajustara automáticamente a la orientación calculada. Esta implementación consideró la disponibilidad de recursos de la plataforma (CPU, memoria, consumo energético) para asegurar la respuesta eficiente del sistema y su funcionamiento estable.


Para construir el prototipo se usaron componentes de fácil acceso y relativamente económicos con el objetivo de no elevar demasiado los costos del proyecto. La estructura del seguidor se realizó con perfiles de aluminio 2020, a la que se le sujetaron los sensores de posicionamiento y los actuadores lineales. Inicialmente se optó por dos módulos encoders magnéticos AS5600, pero debido a fallas en uno de los sensores se reemplazó uno de ellos por un acelerómetro - giroscopio BMI160. De esta forma, el movimiento en torno al eje NS se midió con el BMI160 y el giro alrededor del eje EO se midió con el AS5600.

Los actuadores lineales usados fueron de 12V con una capacidad de 100 Kg y cuentan con protección IP65. El actuador para el eje NS fue de 8" de recorrido lineal, mientras que para

el eje EO es de 6". Cada actuador fue alimentado y controlado a través de un modulo BTS7960 y su consumo fue medido con sensores INA219.

Debido a que no se encontraron disponibles paneles bifaciales de pequeño tamaño, se optó por usar dos paneles solares: un panel solar superior que apunta hacia el cielo monocristalino de 30W conectado a un controlador PWM que carga una batería de 12V y 9Ah, y un panel inferior que mira hacia el suelo de 8W. Ambos paneles se conectaron a dos sensores INA219 para medir la potencia de cada uno y se les conectó una carga lo suficientemente alta para mantener un flujo de corriente ininterrumpida a lo largo de las mediciones, tales como celulares, tabletas, luces LED, y baterías Power Bank.

Las estructura de aluminio se atornilló a una tabla en madera recubierta de barniz y pintura. Mientras que los sensores para el posicionamiento del panel se sujetaron a la estructura con piezas en madera. En la Figura 6 se observa el prototipo armado que soporta y mueve a los dos paneles durante las primeras pruebas en las que se detectaron las fallas en el codificador de posición AS5600 del eje NS.


**Figura 6***Estructura del Seguidor Solar*

*Nota.* Estructura movable hecha en aluminio que soporta el panel solar.

El suministro de energía de los sensores y puentes H se realizó a través de reguladores de voltaje LM2596, los cuales se ubicaron dentro de cajas de material ABS junto con el resto de componentes del circuito de control, tal como se muestra en la Figura 7. Adicionalmente, fueron agregados interruptores y fusibles de protección tanto para el panel de 30W como para las conexiones de la batería.

## Figura 7

### *Circuito Inicial de Control y Lectura de Datos*



*Nota.* Tarjeta de Arduino junto con los módulos del circuito, la batería y el controlador de carga.

## Pruebas y Ajustes

Durante esta fase, se evaluó el desempeño real del sistema y su capacidad de seguimiento. Para ello, se instaló el sistema en las condiciones previstas y se monitorizó su comportamiento y la energía captada durante dos días. Con esto se recopilaban suficientes datos para verificar el correcto funcionamiento del seguimiento inteligente y el seguimiento astronómico. Los resultados se analizaron para cuantificar la mejora en la captación energética y detectar áreas de oportunidad para realizar ajustes en el modelo y en la implementación.

Dado que no se planea una réplica a gran escala, esta retroalimentación se enfocó en perfeccionar la solución para el entorno específico de medición, el cual es una residencia. Una

vez el funcionamiento fue satisfactorio, se documentaron las recomendaciones para un potencial refinamiento futuro del proyecto.

### **Mediciones de Generación de Energía**

Como solo se contó con un prototipo debido a limitaciones en el presupuesto, no fue posible realizar mediciones simultaneas bajo las mismas condiciones para los dos tipos de seguimiento (astronómico e inteligente). Por ende, se tomaron medidas en días intercalados para cada seguimiento, en total cinco días para cada enfoque, y luego se obtuvo un promedio de energía generada. Con este promedio fue que se realizó el análisis de desempeño energético.

Los días del despliegue del prototipo abarcaron una combinación de condiciones nubladas, con lluvia y soleadas, específicamente fueron realizados entre octubre y noviembre puesto que es la época de lluvia para el Caribe colombiano. Estas condiciones son las mas apropiadas para realizar la comparación ya que se espera que la ventaja del seguimiento inteligente con paneles bifaciales se obtenga bajo condiciones de nubosidad (Santos de Araújo et al., 2024).

Para alimentar los modelos predictivos se optó por la plataforma Open-Meteo que calcula valores de las variables requeridas cada hora y puede suministrar datos cada 15 minutos por interpolación, intervalo con el que se actualizó la posición del seguidor. La razón del por qué se eligió este proveedor es su gratuidad para un numero de solicitudes diarias de API menor a 10 mil.

La tarjeta Arduino fue programada para enviar datos al computador a una frecuencia de 1Hz promediando las mediciones hechas cada 100ms (Apéndice A), datos que luego son almacenados en archivos CSV separados por fecha de medición. El código de Python muestra los valores medidos en tiempo real y para no interrumpir todos los procesos se usó una

programación multi-hilo como se muestra en las siguientes líneas de código del seguimiento con Machine Learning y en el Apéndice B:

```
# Hilo para leer datos del serial

if self.arduino:

    self.serial_thread = threading.Thread(target=self.imprimir_guardar, daemon=True)

    self.serial_thread.start()

# Hilo para enviar indicación a Arduino (cada 15 minutos)

self.periodic_thread = threading.Thread(target=self.ejecutar_periodicamente,
daemon=True)

self.periodic_thread.start()

# Hilo para obtener datos de irradiancia (cada 60 minutos)

self.periodic_thread = threading.Thread(target=self.datos_irradiancia, daemon=True)

self.periodic_thread.start()
```

### **Análisis Financiero Comparativo Entre el Seguimiento Astronómico y el Machine Learning**

Para realizar el análisis financiero de los dos métodos de seguimiento se realizó un escalamiento asumiendo la misma eficiencia del panel a un sistema de mayor potencia con especificaciones que una persona o empresa consideraría instalar para auto-generación, incluyendo los costos relacionados a la estructura de soporte, sensores de medición de energía, posicionamiento, motores, baterías, controlador de carga y todos los demás elementos que componen a un sistema fotovoltaico aislado. Los precios de estos se obtuvieron de tiendas en línea como Aliexpress o Amazon, así como también de tiendas locales de electrónica.

Adicionalmente, se hizo una comparación con únicamente los componentes diferenciadores que modifican el hardware necesario para cada método de seguimiento.

Cabe aclarar que los precios y costos fueron analizados teniendo en cuenta el contexto de una instalación pequeña de auto-generación, ya que los criterios son diferentes con respecto a una planta de generación de gran escala para la producción y venta de energía.

Además, se agregaron como referencia dos opciones adicionales que corresponden al uso de modelos de aprendizaje automático pero con fuentes de datos diferentes, uno alimentado con plataformas de datos no gratuitas que ofrecen mayor resolución temporal, y el otro con sensores en el sitio de la instalación fotovoltaica. Sin embargo, estas dos alternativas no fueron implementadas y medidas en el presente proyecto.

También se hace la anotación de que el método de seguimiento astronómico puede programarse tanto con un Single Board Computer (SBC) como también con un microcontrolador, dependiendo de si las posiciones se calculan en tiempo real usando PVLIB de Python o si se calculan previamente y se suministran por medio de una tarjeta de memoria SD al microcontrolador.

## Análisis de Resultados

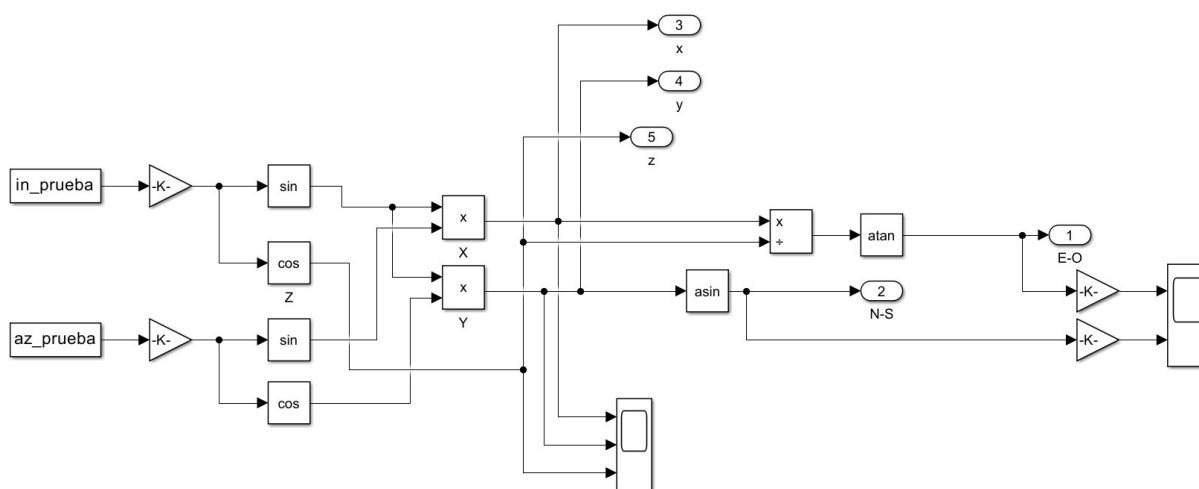
Según los procedimientos descritos en la metodología , los resultados obtenidos son mostrados y analizados en esta sección del documento.

### Algoritmo de Control y Simulación

Debido a que la posición del Sol es manejada en un sistema de coordenadas cilíndricas (Acimut y Cenit) y el sistema de coordenadas del seguidor solar en este proyecto es cartesiano, es necesario realizar una transformación de coordenadas y aplicación de rotacionales para obtener la posición a la que debe ubicarse cada eje de movimiento del seguidor (Figura 8).

### Figura 8

*Algoritmo de Control del Seguidor Solar en Simulink*

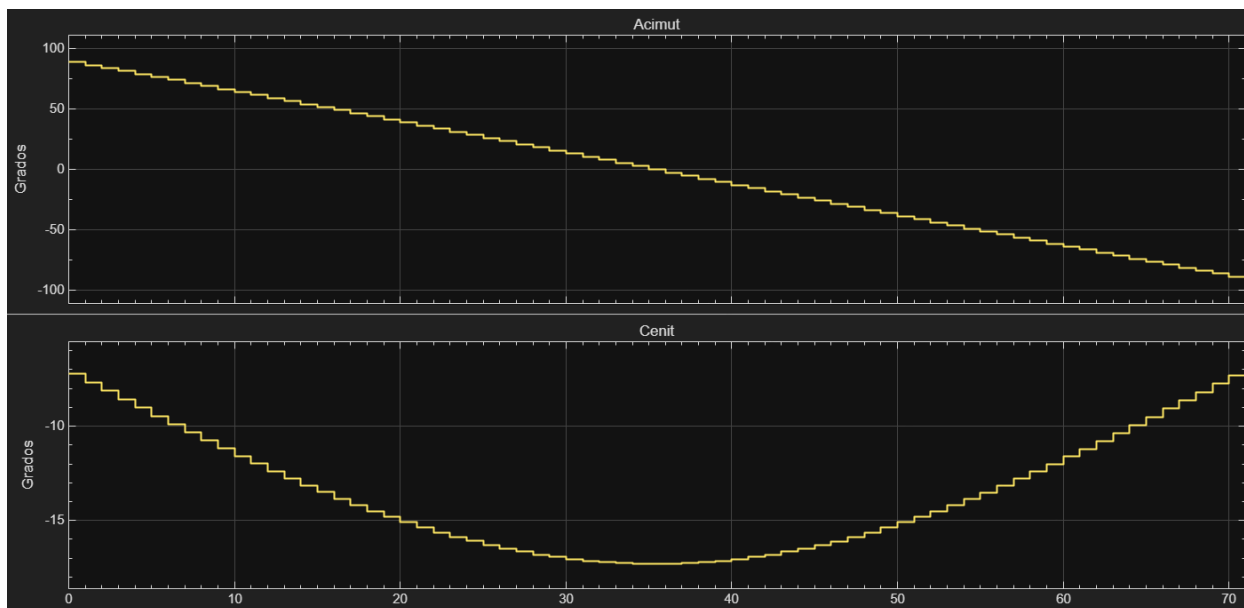


*Nota.* Simulación en Simulink del algoritmo que controla el movimiento del panel.

De la simulación se obtuvo el comportamiento esperado de seguimiento para el día de prueba, tal como se muestra en la Figura 9 y la Figura 10. Por lo que se procedió a usar dicho algoritmo para la elaboración del código de control posicional tanto para la tarjeta de Arduino como para la Raspberry Pi 5.

**Figura 9**


*Posición Simulada en Simulink del Panel Solar para un Día de Prueba*



*Nota.* Curvas de acimut y cenit resultantes de la simulación del algoritmo de control.

**Figura 10**

*Simulación del Movimiento del Seguidor Solar en Simulink*



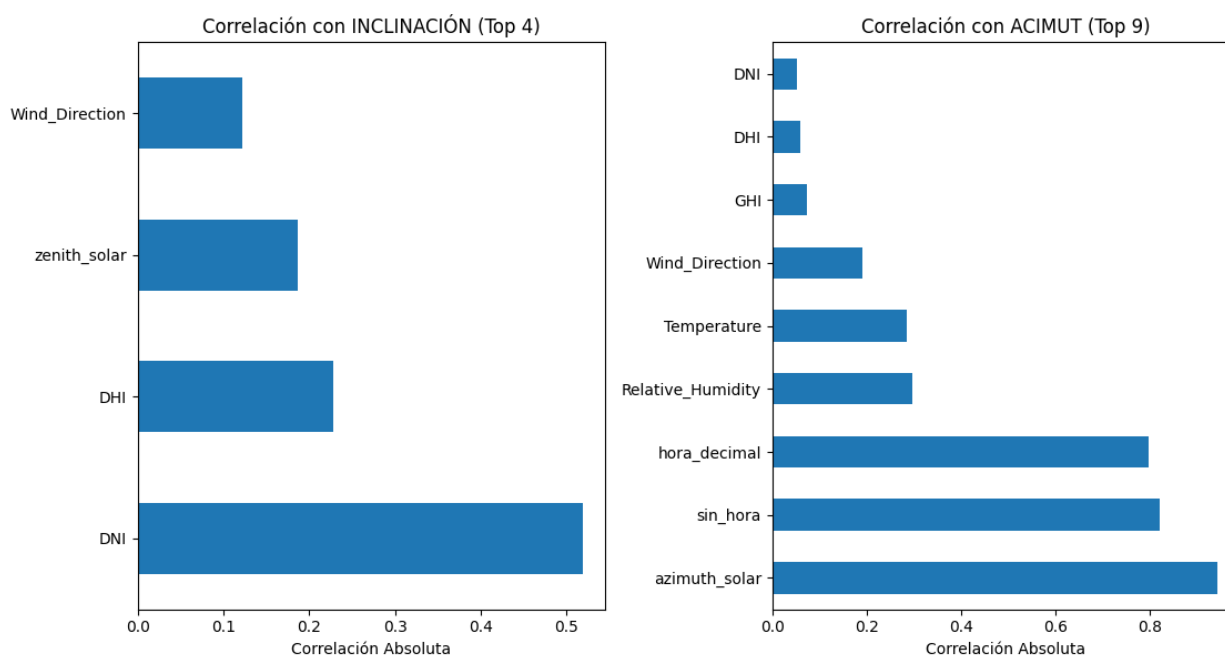
*Nota.* Modelo 3D en Simulink del posicionamiento del panel solar.

## Modelo Random Forest de Posicionamiento

Del análisis de variables con el mRMR se seleccionaron las que se muestran en la Figura 11, siendo el modelo para acimut el que mas variables requiere (nueve) y el modelo de inclinación el que menos entradas necesita (cuatro). En total son 10 variables únicas de las cuales seis se obtuvieron de la base de datos NSRDB del NREL que corresponden a las variables meteorológicas incluidas las radiaciones; la posición acimut y cenit del sol con la librería PVLIB de Python; y las dos variables horarias mediante calculo. Los valores de RMSE en la selección fueron para el acimut  $7.21^\circ$  y para la inclinación  $0.53^\circ$ .

### Figura 11

#### Correlación de Variables Seleccionadas



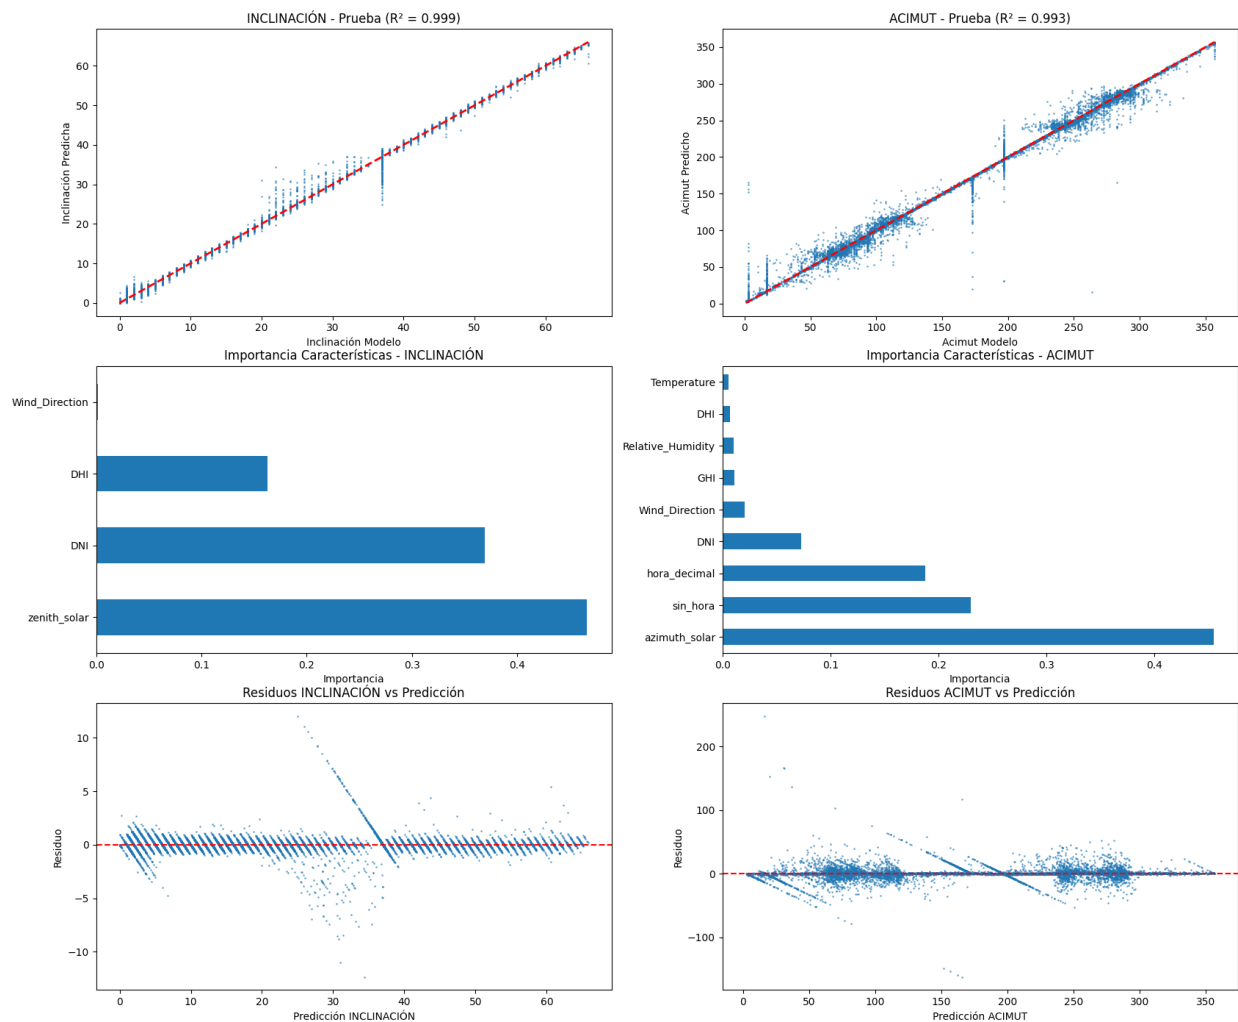
*Nota.* Resultados del algoritmo en Python que evalúa la correlación entre variables.

Ambos modelos entrenados, Inclinación y Acimut, arrojaron un  $R^2$  de 0.99, teniendo en cuenta que las variables objetivos son las posiciones dadas por el algoritmo Infinite Sheds para

paneles bifaciales. Esto indica que los modelos capturan casi toda la variabilidad en los datos y tienen una capacidad predictiva sobresaliente. El desempeño de ambos modelos para el conjunto de datos de prueba se aprecia en la Figura 12.

**Figura 12**

*Resultados y Prueba de Modelos Entrenados*



*Nota.* Comportamiento del modelo en la predicción del acimut y el cenit.

Para la Inclinación las variables más relevantes son el cenit solar, DNI y DHI, sugiriendo que la posición solar y la radiación directa son determinantes clave. Para el Acimut domina

claramente el acimut solar, seguido por la hora senoidal y la hora decimal, indicando que el componente angular y temporal son fundamentales.

El modelo de Inclinación muestra algunos valores atípicos significativos que se deben a los valores cero de posicionamiento cuando el GHI es muy bajo según el método “infinite sheds”. El modelo de Acimut presenta una banda de residuos más amplia pero sin patrones sistemáticos evidentes, lo que sugiere que el error es principalmente aleatorio.

Analizando las métricas de error de ambos modelos, se observó un contraste notable en su precisión absoluta. El modelo de Inclinación presenta un rendimiento excepcional con un RMSE de  $0.6730^\circ$  y un MAE de  $0.2938^\circ$ , lo que significa que en promedio el modelo se equivoca por menos de 0.3 grados, un error prácticamente insignificante para aplicaciones de posicionamiento de paneles solares. Por otro lado, el modelo de Acimut muestra un RMSE de  $7.1756^\circ$  y un MAE de  $2.7838^\circ$ , errores aproximadamente 10 veces superiores. Sin embargo, este resultado debe contextualizarse considerando que el acimut opera en un rango de 0-360 grados (mucho más amplio que la inclinación), y un error promedio de 2.78 grados sigue siendo bastante aceptable para fines prácticos de orientación solar. La diferencia entre RMSE y MAE en ambos casos (más pronunciada en el modelo de Acimut: 7.18 vs 2.78) sugiere la presencia de algunos errores atípicos mayores, lo cual es consistente con la mayor dispersión observada en las gráficas de residuos del modelo de Acimut, aunque estos no comprometen significativamente la utilidad del modelo para determinar la orientación óptima del panel solar.

### **Prototipo Construido del Seguidor Solar**

El circuito implementado para las mediciones se presenta en la Error: no se encontró el origen de la referencia, el cual tiene un consumo promedio constante de 100mA, por lo que no se le agregó un sensor para medir la energía consumida. Por otro lado, el circuito para una

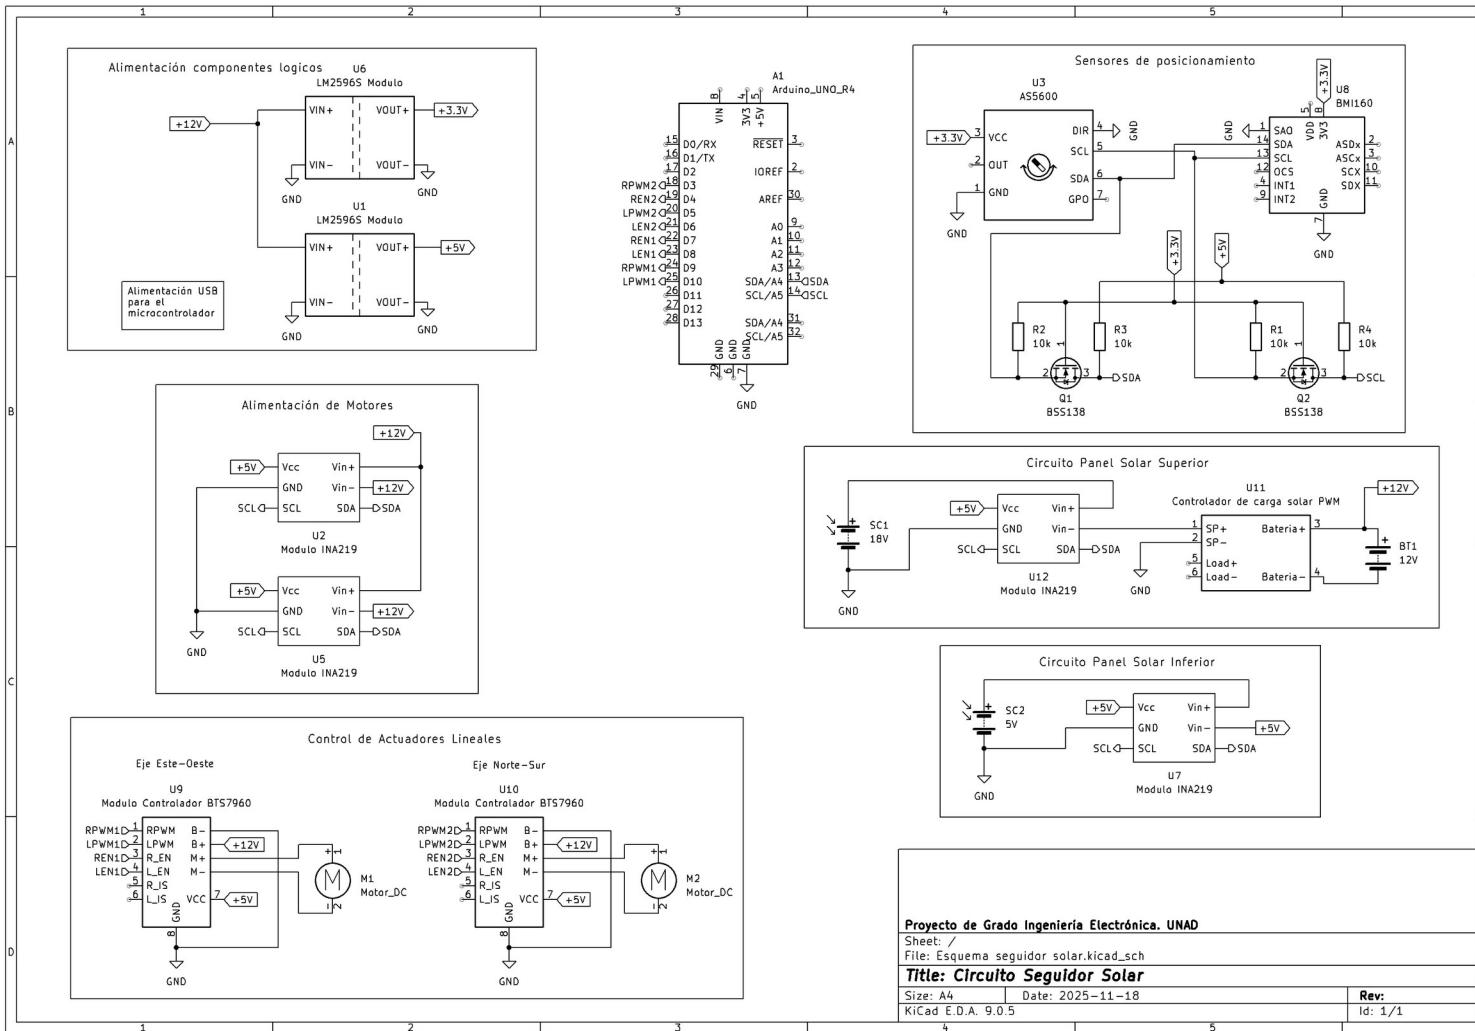
instalación permanente reemplaza la tarjeta Arduino por la Raspberry Pi Zero 2W y no incluye los sensores INA219 puesto que el controlador de carga PWM tiene un sensor de voltaje y no es necesario añadir sensores adicionales.

Mecánicamente, el seguidor solar tiene un movimiento Este-Oeste que va desde los  $-55^\circ$  a  $55^\circ$ , mientras que el movimiento Norte-Sur está entre  $-38^\circ$  y  $38^\circ$ . Esto se debe al alcance de los actuadores usados.


Por otro lado, se descartó el uso de motores paso a paso u otras opciones rotatorias, por la mayor dificultad de implementación, ya que se requiere de componentes adicionales como reductoras y rodamientos de acople, que encarecen el proyecto e incrementan el mantenimiento. La Figura 14 contiene una imagen del sistema final desplegado y operando.

Figura 13

Planos del Circuito Electrónico Usando la Tarjeta Arduino Uno R4 Wifi



Nota. Plano que muestra los módulos usados, la tarjeta de desarrollo, las conexiones, actuadores y sensores.


**Figura 14***Seguidor Solar Operando en Condiciones de Nubosidad*

*Nota.* Fotografía tomada durante las mediciones.

El sistema creado para operar de manera permanente sin las mediciones puede operar con un SBC de bajo costo como una Raspberry Pi Zero 2W para el caso del seguimiento astronómico (Figura 15) o con un SBC de mayor capacidad como una Raspberry Pi 5 para el caso del seguimiento inteligente. Es importante tener en cuenta que para la ejecución de modelos de inteligencia artificial, se necesita mas capacidad de computo y mas memoria RAM disponible dependiendo de las características del modelo entrenado.

## Figura 15

*Sistema Conectado a un SBC de Bajo Costo*



*Nota.* Fotografía del reemplazo de la tarjeta Arduino por una Raspberry Pi Zero 2W.

## Resultados de Mediciones

De los datos recolectados durante los 10 días de mediciones en días nublados y con lluvia, se obtuvieron los resultados y gráficas que se muestran en las siguientes secciones.

### *Generación Energética*

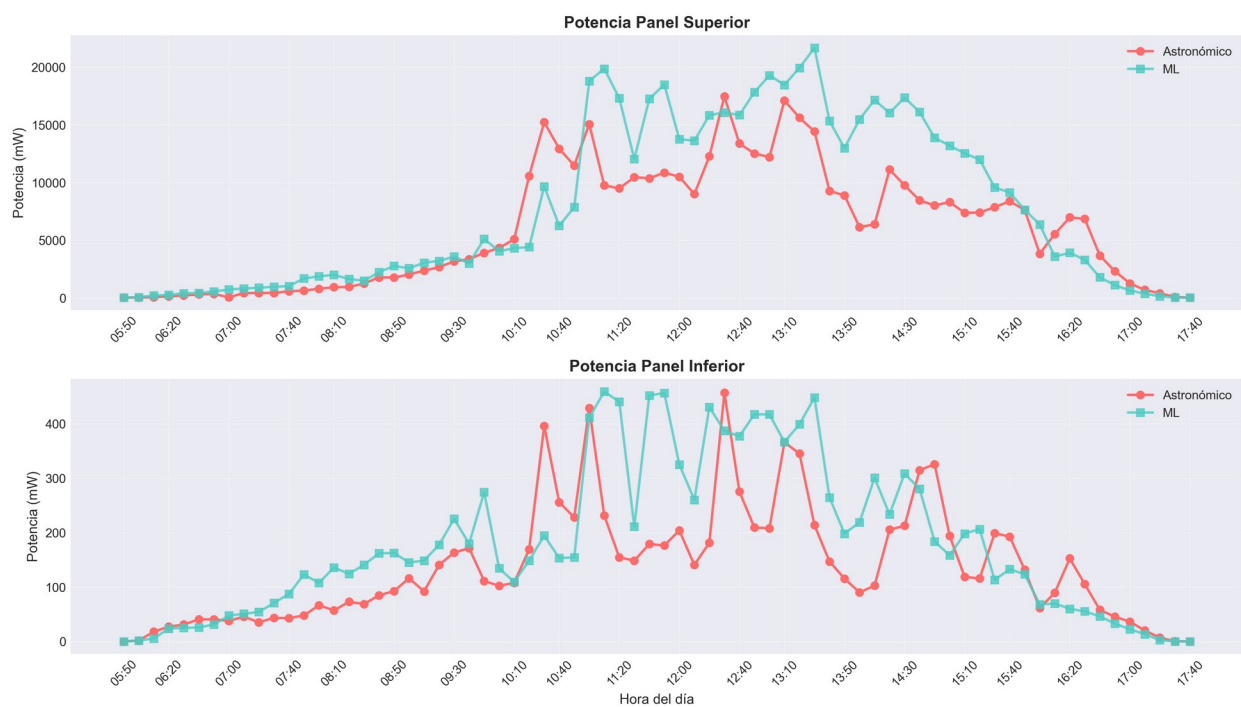
El análisis reveló diferencias significativas en el desempeño energético de ambos métodos. En términos de producción diaria promedio, el sistema con Machine Learning alcanzó

95.91 Wh/día, superando por 18.84 Wh/día al método astronómico que registró 77.07 Wh/día.

Esta mejora representa aproximadamente un 24.44% más de energía capturada diariamente. En la Figura 16 se observan las horas en las que hubo diferencias a favor del seguimiento inteligente en términos de potencia medida para el panel superior e inferior.

**Figura 16**

*Potencia de los Paneles Superior e Inferior*




*Nota.* Valores promedio de potencia generada según las mediciones realizadas.

El panel inferior tiene un patrón similar al superior, puesto que las horas en las que generan mas energía coinciden, lo que da a entender que puede ser una diferencia provocada por radiación disponible y no por posicionamiento distinto. Por otro lado, la energía combinada de ambos paneles se obtiene sumando la energía generada por cada uno, la cual no afecta significativamente el patrón de comportamiento ya visto (Figura 17).

**Figura 17**

*Potencia Instantánea Total del Sistema (Panel Superior + Inferior)*



*Nota.* Comparación con los promedios de la potencia instantánea total medida.

### **Consumo Energético del Sistema**

El análisis de consumo debe considerar tres componentes principales: el consumo de los actuadores lineales, el consumo del sistema de control y el consumo del sistema de control.

**Consumo de los Actuadores Lineales.** Los motores que mueven cada eje solo se activan durante unos segundos cada 15 minutos para ubicar el panel en una nueva posición, mientras que el resto del tiempo están en modo espera cuya carga es de 4 a 5mA y una potencia entre los 50 y 60 mW (Figura 18), eso hace que su consumo sea muy bajo en comparación con la energía generada por el panel solar. El consumo energético de los dos motores presentó valores comparables entre ambos métodos. El seguimiento astronómico consumió 1.36 Wh/día en actuación, mientras que el Machine Learning requirió 1.37 Wh/día, representando una diferencia de apenas 0.01 Wh o un 0.7% adicional.

**Figura 18***Consumo Medio Instantáneo de los Actuadores Lineales*

*Nota.* Consumos promedio de los actuadores medidos con los INA219.

**Consumo del Sistema de Control.** El circuito lógico compuesto por los sensores, los controladores puente H y el Arduino UNO R4 Wifi, presenta un consumo promedio de 100mA. Considerando una operación continua a 5V durante aproximadamente 12 horas diarias de operación activa del sistema, se obtiene un consumo por día de 6 Wh/día y en los 5 días un consumo total de 30 Wh. Este consumo es idéntico para ambos métodos, ya que utilizan la misma plataforma de control.

**Consumo Total del Sistema.** El consumo total diario del sistema fue similar para ambos métodos de seguimiento, quedando de la siguiente manera:

- Astronómico:  $1.36 \text{ Wh/día} (\text{motores}) + 6 \text{ Wh/día} (\text{control}) = 7.36 \text{ Wh/día}$

- Machine Learning:  $1.37 \text{ Wh/dia (motores)} + 6 \text{ Wh/dia (control)} = 7.37 \text{ Wh/dia}$

### ***Eficiencia Neta del Sistema***


Considerando el balance energético completo, que equivale a la generación menos el consumo de total, se obtuvieron las siguientes eficiencias neta por día:

- Astronómico:  $\text{Energía neta} = 77.07 - 7.36 = 69.71 \text{ Wh/dia}$  (90.4% de eficiencia neta)
- Machine Learning:  $\text{Energía neta} = 95.91 - 7.37 = 88.54 \text{ Wh/dia}$  (92.3% de eficiencia neta)

Cuando se considera el consumo completo del sistema de control, la eficiencia neta se reduce para ambos métodos. Sin embargo, el método de Machine Learning mantiene una ventaja significativa de 18.83 Wh/día adicionales (27% más energía neta), además de lograr una eficiencia neta superior en 1.9 puntos porcentuales. En la Figura 19 se observa que la ventaja del seguimiento con ML esta en las horas centrales del día, desde aproximadamente las 11:00 horas hasta las 15:30 horas.

### **Figura 19**

#### *Eficiencia Neta del Sistema (Generación - Consumo Motores)*



*Nota.* Comparación de eficiencia neta que equivale a la resta de la generación menos el consumo de los motores.

Es importante destacar que el consumo del sistema de control representa una proporción considerable de la energía generada en esta configuración experimental con paneles de pequeño tamaño (9.6% para astronómico, 7.7% para Machine Learning). En instalaciones con paneles de mayor capacidad, este consumo del control se volvería proporcionalmente insignificante. Por ejemplo, en un sistema con paneles de 300W, el mismo circuito de control consumiría menos del 1% de la generación típica, haciendo que las ganancias del ML o el seguimiento astronómico sean mucho más evidentes en términos de energía neta aprovechable.

### ***Análisis del Comportamiento Angular***

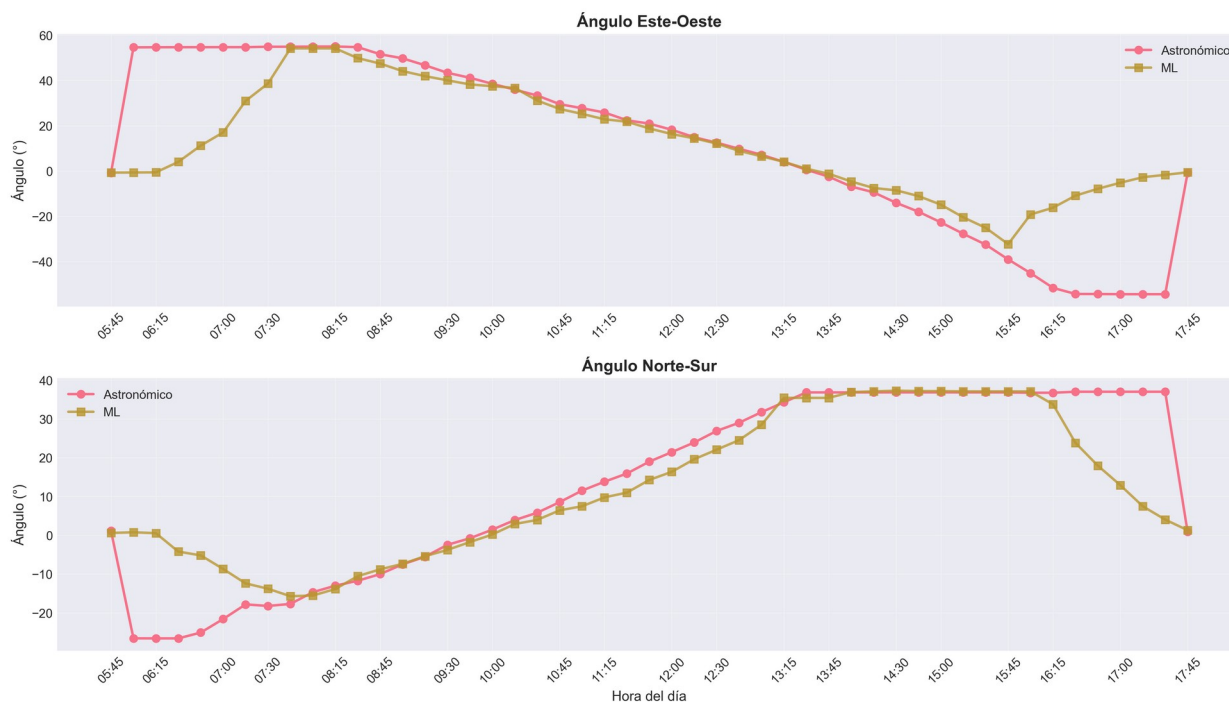
Debido a que los ángulos medidos no corresponden directamente al acimut y el cenit de un sistema de coordenadas esféricas, deben interpretarse dentro de un sistema de coordenadas cartesianas en el que el ángulo Este-Oeste corresponde al movimiento del panel en esa dirección y de manera análoga con el ángulo Norte-Sur. Adicionalmente, debe considerarse el desvío angular de  $43^\circ$  en sentido horario medido desde el Norte geográfico con el que se instaló el seguidor solar, esto implica que el sistema de referencia del seguidor no está alineado con los puntos cardinales verdaderos. Esta desalineación implica que los movimientos de los actuadores combinan componentes de seguimiento tanto del azimut como de la elevación solar, transformados al marco de referencia rotado del dispositivo.

**Ángulo Este-Oeste (Movimiento en Dirección EO).** Las gráficas de posicionamiento angular revelan patrones distintivos en cada método (Figura 20). El seguimiento astronómico muestra una trayectoria suave y predecible que alcanza rápidamente su posición inicial (aproximadamente  $+55^\circ$  a las 05:50), mantiene valores relativamente constantes durante la mañana temprana, y desciende progresivamente a lo largo del día hasta alcanzar aproximadamente  $-55^\circ$  al finalizar la tarde (17:45). Esta curva representa la trayectoria teórica

del sol en el plano horizontal.

**Figura 20**

*Ángulo de Posicionamiento del Seguidor Solar*



*Nota.* Posicionamiento promedio del panel en los dos ejes.

En contraste, el método de Machine Learning presenta un comportamiento notablemente diferente en las horas iniciales del día. El sistema permanece en posición cercana a  $0^\circ$  hasta aproximadamente las 06:30, momento en que comienza un ascenso más pronunciado hacia los  $+55^\circ$ . Esta diferencia inicial sugiere que el modelo identifica condiciones de baja radiación o alta nubosidad matutina, optando por capturar la radiación difusa por ambas caras del panel y como consecuencia se conserva energía de los actuadores al no seguir la posición solar teórica cuando el beneficio energético es marginal.

Durante el período central del día (08:00-15:45), ambos métodos convergen en

trayectorias similares, aunque el ML muestra ajustes ligeramente más conservadores. Sin embargo, hacia el final del día (15:45-17:30), el sistema de Machine Learning nuevamente presenta un comportamiento diferenciado, mostrando un retorno más temprana hacia posiciones cercanas a  $0^\circ$  antes que el método astronómico que llega al máximo de  $-55^\circ$ , posiblemente anticipando condiciones de baja irradiancia.

**Ángulo Norte-Sur (Movimiento en Dirección NS).** El eje Norte-Sur muestra diferencias entre ambos métodos de manera análoga al movimiento EO. El seguimiento astronómico exhibe una transición constante desde aproximadamente  $-25^\circ$  hasta  $+37^\circ$  entre las 06:00 y las 13:30, manteniéndose estable durante la tarde hasta descender a su posición de reposo al final del día una vez que el Sol está por debajo del horizonte.

El sistema de Machine Learning, por otra parte, inicia con ángulos cercanos a  $0^\circ$  y presenta una elevación más gradual durante la mañana. Esta diferencia es notoria entre las 06:00 y las 7:30, donde el ML mantiene consistentemente ángulos entre  $0^\circ$  y  $-15^\circ$ , lo que significa menor inclinación en comparación con el método astronómico. Esta estrategia resulta especialmente efectiva en las condiciones del amanecer o en condiciones de nubosidad, donde la radiación difusa predomina sobre la directa y los ángulos óptimos difieren significativamente de la posición solar teórica.

El método astronómico alcanza valores máximos de aproximadamente  $+37-38^\circ$  y los mantiene estables durante un período más prolongado (13:00-17:45), mientras que el método inteligente comienza a descender más temprano. Al final del día el astronómico ejecuta un retorno a la posición de reposo, descendiendo desde  $+37^\circ$  hasta  $0^\circ$ , mientras el método ML hace una transición a medida que el Sol se acerca al horizonte y la radiación difusa DHI es más relevante.

## **Análisis Financiero Comparativo Entre Métodos de Seguimiento**

El Retorno de Inversión (ROI) del seguimiento astronómico para el sistema de prueba con paneles de 38W totales y un costo promedio de energía igual a \$860 COP/kWh:

- Ganancia energética: 25.44 kWh/año
- Ahorro monetario anual:  $25.44 \text{ kWh} \times \$ 860 / \text{kWh} = \$ 21,878.4 \text{ COP} / \text{año}$

Para el caso del seguimiento con aprendizaje automático usando Open-Meteo, el ROI es:

- Ganancia energética: 32.32 kWh/año
- Ahorro monetario anual:  $32.32 \text{ kWh} \times \$ 860 / \text{kWh} = \$ 27,795.2 \text{ COP} / \text{año}$

En el prototipo de pequeña escala, el ROI es limitado debido a que la capacidad nominal del sistema es de apenas 38W y a que el consumo de control representa una fracción significativa de la generación. Sin embargo, el valor real radica en la validación tecnológica.

### ***Sistema Escalado de Mayor Potencia***

Asumiendo la misma eficiencia energética, si aplicamos un factor de escalamiento a la energía generada por un sistema compuesto de dos paneles bifaciales comerciales de 600W que en total aportarían 1200W de potencia y consideramos un ajuste de consumo a 24h seguidas de funcionamiento, obtenemos para el seguimiento astronómico:

- Factor de escalamiento:  $1200 \text{ W} / 38 \text{ W} = 31.58$   
 $(31.58 \times 77.07 \text{ Wh} / \text{dia} - 16 \text{ Wh} / \text{dia}) \times 365 \text{ dias} / 1000 = 882.5 \text{ kWh} / \text{año}$
- Ganancia energética: 882.5 kWh/año
- Ahorro monetario anual:  $882.5 \text{ kWh} / \text{año} \times \$ 860 / \text{kWh} = \$ 758,950 \text{ COP} / \text{año}$
- Ahorro en 10 años: \$8,700,511 COP (considerando inflación anual del 3%)

Mientras que para el seguimiento con machine learning y un consumo mayor por el SBC mas potente y su conexión a internet, tendríamos:

$$(31.58 \times 95.91 \text{ Wh/día} - 130 \text{ Wh/día}) \times 365 \text{ días} / 1000 = 1058.07 \text{ kWh/año}$$

- Ganancia energética: 1058.07 kWh/año
- Ahorro monetario anual:  $1058,07 \text{ kWh/año} \times \$ 860/\text{kWh} = \$ 909,940.2 \text{ COP/año}$
- Ahorro en 10 años: \$10,431,444 COP (considerando inflación anual del 3%)

Para este sistema de 1200W, el costo de la estructura metálica, los actuadores, codificadores, controladores, batería, panel, inversor, entre otros elementos, estaría en \$4,601,100 más los valores mostrados en la Tabla 1 que dependen del método seleccionado. Esta tabla contiene los elementos diferenciadores que afectan los presupuestos para distintas opciones de seguimiento, aunque las dos alternativas adicionales no se implementaron ni se midieron en este proyecto, la cuales son: plataformas no gratuitas de datos y sensores meteorológicos en sitio.

El sistema escalado presupuestado tiene las siguientes especificaciones y la tabla de costos se muestra en el Apéndice D:

- Dos paneles bifaciales de 600W.
- Batería gel de 12V y 250Ah.
- Controlador de carga MPPT de 12/24 V
- Inversor de 12V
- Estructura de acero soldada y protegida con anticorrosivo
- Dos actuadores lineales de 12V y 3000N de carga máxima.
- Dos codificadores (encoders) incrementales de 600p/r.

Por lo tanto, el sistema con seguimiento astronómico tendría un costo total durante 10 años de uso de \$5,561,100, mientras que el seguimiento con Machine Learning y Open-Meteo costaría entre \$5,891,100 y \$8,786,274, dependiendo de si se debe agregar un servicio de internet. De lo que se deduce que para un sistema con estas características se podría recuperar el

dinero invertido en menos de 10 años, específicamente 6-7 años para el primer caso y 7-10 años para el segundo. La ventaja del seguimiento inteligente estaría en el caso de que ya se cuente con el servicio a internet puesto que la inversión se recuperaría en aproximadamente 6 años y a partir de allí se obtendrían los beneficios de una mayor generación de energía.

**Tabla 1**

*Variación de Presupuesto para una Generación de Pequeña Escala Durante 10 Años*

Ítem	Nota	Astronómico	Machine Learning (Open-Meteo)	Machine Learning (datos pagos)	Machine Learning (datos en sitio)
SBC de bajo costo (Raspberry Pi Zero 2, Orange Pi Zero 2, entre otros)	Precio de la Orange Pi Zero 2W	\$120,000.00	\$0	\$0	\$0
SBC costo medio (Raspberry Pi 5, Orange Pi 5, entre otros)	Mas capacidad de computo y memoria RAM	\$0	\$450,000.00	\$450,000.00	\$450,000.00
Anemómetro	Opcional pero recomendable por seguridad. Obligatorio para datos en sitio.	\$110,000.00	\$110,000.00	\$110,000.00	\$0
Piranómetro	Mide GHI	\$0	\$0	\$0	\$600,000.00
Pirheliómetro	Mide DNI	\$0	\$0	\$0	\$1,400,000.00
Estación meteorológica completa	Temperatura, humedad, presión, velocidad y dirección del viento	\$0	\$0	\$0	\$495,000.00
Suscripción API (10 años)	Asumiendo tasa de ajuste del 3% y precio anual actual de la plataforma Steady-Sun	\$0	\$0	\$27,399,000.00	\$0
Servicio de Internet (10 años)	Solo si no hay servicio	\$0	2,895,174.03	2,895,174.03	\$0
Mantenimiento (10 años)	Se asume la avería de componentes baratos, cables y/o conexiones	\$150,000.00	\$150,000.00	\$150,000.00	\$400,000.00
	Total sin internet	\$380,000.00	\$710,000.00	\$28,109,000.00	\$3,345,000.00
	Total con internet	N/A	\$3,605,174.03	\$31,004,174.03	N/A

*Nota.* Comparación de los costos asociados a cada instalación según el método de control.

Con respecto a las otras plataformas no gratuitas, estas no son financieramente viables para proyectos de auto-generación de pequeña escala como el que se está analizando, puesto que su costo es bastante alto y las mejoras en generación energética pueden no ser suficientes para compensar el dinero invertido. Las plataformas pagas podrían justificarse para plantas productoras de energía que tengan múltiples seguidores solares dentro de la instalación y puedan recuperar la inversión.

En cuanto a los sensores de radiación y meteorología in situ, aunque menos costoso que los datos pagos, hacen que el tiempo de recuperación de la inversión pueda extenderse considerablemente dependiendo del costo de los sensores usados. Aunque tiene el punto a favor de capturar en tiempo real las variaciones meteorológicas con mas precisión y de eliminar la dependencia de una conexión a internet.

En la Tabla 2 se encuentra de manera consolidada y resumida la conclusión de la comparación de las alternativas de seguimiento analizada.

**Tabla 2***Comparación de las Alternativas de Seguimiento Solar*

Opción de seguimiento	Seguimiento astronómico	Seguimiento inteligente con datos meteorológicos gratuitos (Open-Meteo)	Seguimiento inteligente con datos meteorológicos pagos (API de alta resolución)	Seguimiento inteligente con sensores meteorológicos en sitio
Costos principales (CAPEX o capital desembolsado/OP EX o gastos operacionales)	Bajo costo (solo cálculo matemático). No requiere datos externos. OPEX casi nulo.	CAPEX medio por mayor complejidad computacional. OPEX bajo porque los datos son gratuitos, pero requiere internet. No requiere sensores locales.	CAPEX medio-alto. OPEX moderado (suscripciones a plataformas). Datos precisos.	CAPEX alto (sensores, calibración, instalación). OPEX bajo a moderado (mantenimiento de sensores).
Requerimientos técnicos	Single Board Computer (SBC) de bajo costo. Algoritmo astronómico estándar.	SBC más potente. Conexión a internet para descargar datos. Modelo ML entrenado con datos externos.	Hardware similar a la opción previa. Conexión a internet. Integración API confiable.	Estación meteorológica local. Integración de sensores con controlador. Modelo ML entrenado con datos propios.
Ventajas	Muy económico. Preciso bajo condiciones despejadas. Independiente de internet o sensores externos. Fácil mantenimiento.	Mejora la eficiencia en días nublados. Baja inversión en datos. Combina predicciones y optimización energética.	Datos de alta resolución y actualizaciones constantes. Mayor precisión del modelo ML. Mejor desempeño energético en condiciones dinámicas.	Mayor precisión local. Resiliente a caídas de internet. Ideal para ML con datos de alta calidad.
Desventajas	No optimiza según condiciones de nubosidad. No corrige errores difusión alta. Producción ligeramente menor frente a modelos dinámicos.	Dependencia de internet. Datos meteorológicos gratuitos pueden perder resolución o exactitud local. Requiere más desarrollo y pruebas.	Costos recurrentes por suscripción. Dependencia total de internet. A largo plazo eleva significativamente el OPEX.	Inversión inicial alta. Requiere calibración periódica. Mantenimiento más complejo.
Cuándo considerar	Proyectos de bajo presupuesto. Instalaciones aisladas o rurales. Sistemas donde la simplicidad es prioritaria.	Proyectos académicos de optimización. Sistemas conectados a red de datos. Cuando se busca eficiencia adicional sin aumentar demasiado los costos.	Proyectos comerciales medianos o grandes. Plantas donde la ganancia energética compensa el costo de datos. Cuando se busca optimización continua con ROI medible.	Plantas solares medianas y grandes. Proyectos con ROI alto y seguimiento solar crítico. Sistemas con alta variabilidad local.

*Nota.* Comparación realizada a partir del análisis de costos.

## Conclusiones

El sistema de seguimiento basado en Machine Learning demostró un desempeño superior al método astronómico tradicional, con un incremento del 24.44% en la generación energética total y un 27% más de energía neta aprovechable. Esta mejora es destacable considerando que las mediciones se realizaron predominantemente bajo condiciones meteorológicas adversas (días nublados o lluviosos), escenario donde la literatura científica indica que el aprendizaje automático puede ofrecer sus mayores ventajas frente a métodos astronómicos tradicionales. Sin embargo, al no realizarse una comparación con dos prototipos simultáneamente se debe tener en cuenta que puede haber alteraciones por diferencias en las condiciones climáticas de los días medidos.

Las trayectorias angulares, interpretadas en el sistema de coordenadas cartesianas EO-NS del dispositivo, revelan que esta mejora no se debe a un seguimiento más preciso de la posición solar teórica proyectada, sino a una adaptación que optimiza su movimiento según la producción energética. El modelo pondera las condiciones meteorológicas, distribución de radiación directa y difusa y patrones de irradiancia históricos.

El modelo Random Forest evidenció capacidad de desarrollar estrategias no intuitivas como el retraso matutino en posicionamiento, la estabilización prolongada en ángulos óptimos para radiación difusa, e incluso un reposicionamiento anticipatorio al final del día.

Aunque el consumo del sistema de control representa una proporción considerable en esta configuración experimental con paneles pequeños (7.7% de la generación para ML), dicha variable se volvería insignificante en instalaciones de mayor escala, donde las ganancias del sistema serían proporcionalmente mucho mayores. Los resultados sugieren que en sistemas comerciales de 1200W o más, operando bajo condiciones meteorológicas variables, el método de

Machine Learning podría ofrecer ventajas económicas a través de incrementos en la producción energética anual.

Del análisis comparativo entre las distintas alternativas de seguimiento solar se concluye que el seguimiento astronómico representa la opción más económica y sencilla de implementar. Su bajo costo y mínima demanda computacional lo convierten en una solución adecuada para sistemas pequeños, instalaciones de bajo presupuesto o proyectos de investigación. En escenarios donde el incremento de energía obtenido mediante técnicas más avanzadas no compensa la inversión adicional, este método ofrece una excelente relación costo-beneficio.

Por su parte, el seguimiento basado en modelos de aprendizaje automático utilizando datos gratuitos como Open-Meteo se posiciona como la alternativa inteligente más costo-efectiva. Esta opción permite mejorar la captación energética con un gasto adicional mínimo, ya que no requiere sensores locales ni suscripciones a plataformas costosas. Debido a su equilibrio entre rendimiento y costo, resulta especialmente atractivo para instalaciones de pequeña escala, prototipos avanzados, o trabajos académicos, siempre y cuando se cuente con una conexión permanente a internet.

En contraste, el uso de modelos inteligentes apoyados en plataformas meteorológicas pagas incrementa la precisión al disponer de datos de mayor resolución temporal de hasta 5 minutos, pero introduce costos operativos recurrentes. Su adopción solo se justifica cuando el aumento en la producción energética supera de manera consistente los gastos por suscripción, lo cual la orienta principalmente a proyectos donde el rendimiento adicional tiene un impacto económico medible y significativo. Por lo tanto, no es una opción financieramente viable para proyectos de auto-generación de pequeña escala.

Finalmente, el seguimiento inteligente basado en sensores meteorológicos in situ

constituye la opción más robusta y profesional, especialmente en plantas solares de mediana y gran escala. Aunque implica una mayor inversión inicial debido a la adquisición e instalación de sensores especializados, ofrece datos locales de alta calidad que permiten entrenar y operar algoritmos avanzados con máxima precisión. Esta alternativa resulta financieramente atractiva en proyectos donde la variabilidad climática local influye de manera significativa en el rendimiento del sistema y donde la mejora en eficiencia energética puede compensar el mayor costo inicial.

En conclusión, este estudio valida que la inteligencia en la toma de decisiones de posicionamiento informada por datos meteorológicos, supera al seguimiento astronómico, especialmente en las condiciones de cielo variable que predominan en muchas regiones tropicales. Esto establece al aprendizaje automático como una estrategia prometedora y práctica para optimizar sistemas de seguimiento solar en plantas de producción energética de pequeña y gran escala.

## Recomendaciones

Con base en los resultados obtenidos durante el desarrollo de este proyecto y considerando las limitaciones identificadas, así como las oportunidades de mejora detectadas, se presentan algunas recomendaciones orientadas a trabajos futuros y a la implementación práctica de sistemas de seguimiento solar.

Se recomienda la incorporación de sensores meteorológicos locales de bajo costo (piranómetro, anemómetro, sensor de temperatura y humedad) que permitan la captura de datos en tiempo real con frecuencias superiores a los 15 minutos, eliminando la dependencia de plataformas externas y mejorando la capacidad de respuesta del modelo de Machine Learning ante cambios atmosféricos súbitos. Esta implementación permitiría evaluar si la ventaja observada puede incrementarse con datos de mayor resolución temporal.

Es aconsejable realizar pruebas experimentales adicionales durante períodos prolongados que abarquen diferentes estaciones climáticas y una mayor proporción de días soleados, con el fin de caracterizar completamente el desempeño del sistema bajo el espectro completo de condiciones meteorológicas posibles. Esto permitiría determinar si el método de Machine Learning mantiene su superioridad en condiciones de cielo despejado o si la ventaja se concentra específicamente en escenarios de radiación difusa.

Se sugiere explorar la implementación de técnicas de aprendizaje profundo como redes neuronales recurrentes o redes convolucionales que puedan capturar patrones temporales más complejos en las series de tiempo meteorológicas y potencialmente superar el desempeño del modelo Random Forest utilizado. Adicionalmente, se recomienda la implementación de aprendizaje por refuerzo donde el sistema aprenda de manera continua y autónoma a partir de su propia experiencia operativa.

Para validar las proyecciones de escalabilidad presentadas en este trabajo, se recomienda replicar el experimento con paneles solares bifaciales de mayor capacidad (500-700W) que permitan evaluar la relación costo-beneficio en condiciones reales de implementación. Esto incluiría el análisis de viabilidad económica considerando costos de inversión inicial, mantenimiento, vida útil del sistema y tarifas eléctricas locales para determinar períodos de retorno de inversión específicos.

Es importante considerar la implementación de sistemas de monitoreo remoto y telemetría que permitan la supervisión continua del desempeño del seguidor, la detección temprana de fallas y la recopilación de datos operativos a largo plazo. Estos datos serían invaluable para el reentrenamiento periódico del modelo de Machine Learning y la optimización continua del sistema.

Finalmente, se sugiere continuar esta línea de investigación explorando la aplicación de técnicas de inteligencia artificial en otros aspectos de sistemas fotovoltaicos, tales como detección automática de fallas, predicción de degradación de paneles, optimización de topologías de arreglos y gestión inteligente de sistemas de almacenamiento energético, contribuyendo así al desarrollo de una nueva generación de sistemas solares verdaderamente autónomos e inteligentes.

### Referencias Bibliográficas

- A. R. Singh, A. Dalmia, C. Mittal, S. Rajshree, S. Singh, & A. Sharma. (2025). Intelligent Dual Axis Solar Tracking System for Energy Generation Optimization in EV Charging Station. *2025 IEEE 5th International Conference on Sustainable Energy and Future Electric Transportation (SEFET)*, 1–6. <https://doi.org/10.1109/SEFET65155.2025.11255579>
- Alici, H., Esenboga, B., Oktem, I., Demirdelen, T., & Tumay, M. (2021). Chapter 7—Designing and performance analysis of solar tracker system: A case study of Çukurova region. En A. T. Azar & N. A. Kamal (Eds.), *Design, Analysis, and Applications of Renewable Energy Systems* (pp. 165–184). Academic Press. <https://doi.org/10.1016/B978-0-12-824555-2.00004-6>
- Amelia, A. R., Irwan, Y. M., Safwati, I., Leow, W. Z., Mat, M. H., & Rahim, M. S. A. (2020). Technologies of solar tracking systems: A review. *IOP Conference Series: Materials Science and Engineering*, 767(1), 012052. <https://doi.org/10.1088/1757-899X/767/1/012052>
- Anderson, K. S., Hansen, C. W., Holmgren, W. F., Jensen, A. R., Mikofski, M. A., & Driesse, A. (2023). pplib python: 2023 project update. *Journal of Open Source Software*, 8(92), 5994. <https://doi.org/10.21105/joss.05994>
- Baena Paz, G. M. E. (2017). *Metodologia de la investigacion*. Grupo Editorial Patria. <https://elibro-net.bibliotecavirtual.unad.edu.co/es/ereader/unad/40513?page=33>
- Bora, B., Dhar, A., Yadav, D., & Kumar, M. N. (2025). Bifacial PV technology. En D. Magare, P. Trivedi, & K. V. Khandeparkar, *Photovoltaic Modules* (1a ed., pp. 126–160). CRC Press. <https://doi.org/10.1201/9781003623168-6>

Bushong, S. (2016, febrero 16). *What is UL 3703?* Solar Power World.

<https://www.solarpowerworldonline.com/2016/02/what-is-ul-3703/>

Carlos Véliz. (2020). *Aprendizaje automático. Introducción al aprendizaje profundo*. El Fondo Editorial de la Pontificia Universidad Católica del Perú. eBook Collection (EBSCOhost).

<https://research-ebSCO-com.bibliotecavirtual.unad.edu.co/linkprocessor/plink?>

[id=ce5684a0-3962-337a-9d62-8b2e57178be1.](https://research-ebSCO-com.bibliotecavirtual.unad.edu.co/linkprocessor/plink?id=ce5684a0-3962-337a-9d62-8b2e57178be1)

*Código eléctrico colombiano*. (2020). ICONTEC.

Defelipe Díaz, S. (2025, febrero 27). Colombianos desarrollan el primer seguidor solar que revoluciona la transición energética. *ImpactoTIC*. <https://impactotic.co/ciencia/desarrollo-sostenible/zentrack-lanza-el-primer-seguidor-solar-hecho-en-colombia/>

Energía Estratégica. (2023, septiembre 22). *TrinaTracker consigue un pedido de un sistema de seguidores solares inteligente de 108 MW en Colombia*.

<https://www.energiaestrategica.com/trinatracker-consigue-un-pedido-de-un-sistema-de-seguidores-solares-inteligente-de-108-mw-en-colombia/#>

Energía Estratégica. (2025, enero 20). *Arctech Solar diversifica su oferta de trackers flexibles para proyectos en Latinoamérica*. <https://www.energiaestrategica.com/arctech-solar-diversifica-su-oferta-de-trackers-flexibles-para-proyectos-en-latinoamerica/>

Harar, D. (2022, abril 26). *Feature Selection for the Lazy Data Scientist* [Towards Data Science]. <https://towardsdatascience.com/feature-selection-for-the-lazy-data-scientist-c31ba9b4ee66/>

IEA. (2025). *Renewables 2025*. IEA. <https://www.iea.org/reports/renewables-2025>

Ini, L. (2025, agosto 6). Primera licencia ambiental bajo el nuevo régimen para un proyecto solar de casi 80 MW en Colombia. *pv magazine*.

<https://www.pv-magazine-latam.com/2025/08/06/primera-licencia-ambiental-bajo-el-nuevo-regimen-para-un-proyecto-solar-de-casi-80-mw-en-colombia/>

International Electrotechnical Commission. (2017). *Photovoltaic systems: Design qualification of solar trackers*. International Electrotechnical Commission.

K. K. R, R. A. Kumar, & M. M. C. (2024). A Maximum Relevance Minimum Redundancy and Random Forest based feature selection and classification of gene expression data. *2024 5th International Conference for Emerging Technology (INCET)*, 1–5.

<https://doi.org/10.1109/INCET61516.2024.10593541>

Kazem, H. A., Chaichan, M. T., Al-Waeli, A. H. A., & Sopian, K. (2024). Recent advancements in solar photovoltaic tracking systems: An in-depth review of technologies, performance metrics, and future trends. *Solar Energy*, 282, 112946.

<https://doi.org/10.1016/j.solener.2024.112946>

Kumar Tyagi, D. A., Kumar Sharma, D. A., & Tripathi, D. K. (2024). *Advanced Machine Learning: Fundamentals and algorithms (English Edition)*. BPB Publications.

Kumba, K., Upender, P., Buduma, P., Sarkar, M., Simon, S. P., & Gundu, V. (2024). Solar tracking systems: Advancements, challenges, and future directions: A review. *Energy Reports*, 12, 3566–3583. <https://doi.org/10.1016/j.egy.2024.09.038>

Lara-Vargas, F. A., Vargas-Salgado, C., Águila-León, J., & Díaz-Bello, D. (2025). Optimizing Bifacial Solar Modules with Trackers. *Advanced Temperature Prediction Through Symbolic Regression †*, 18(8). (SCOPUS:105003711925).

<https://doi.org/10.3390/en18082019>

- Lerma Gonzalez, H. D. (2016). *Metodologia de la investigacion: Propuesta, anteproyecto y proyecto*. Ecoe Ediciones.  
<https://elibro-net.bibliotecavirtual.unad.edu.co/es/ereader/unad/132398?page=73>
- López Ortega, D. J. (2025, abril 2). Crece interés en proyectos de autogeneración de energía en el Caribe: Air-e Intervenida gestiona 1.901 solicitudes. *El Tiempo*.  
<https://www.eltiempo.com/colombia/barranquilla/crece-interes-en-proyectos-de-autogeneracion-de-energia-en-el-caribe-air-e-intervenida-gestiona-1-901-solicitudes-3440916>
- Maniscalco, M. P., Longo, S., Micciché, G., Cellura, M., & Ferraro, M. (2024). A Critical Review of the Environmental Performance of Bifacial Photovoltaic Panels. *Energies* (19961073), 17(1), 226. Academic Search Ultimate (174714894).  
<https://doi.org/10.3390/en17010226>
- Marsh, W. M., & Kaufman, M. M. (2013). The Effect of the Atmosphere on Solar Radiation. En *Physical geography: Great systems and global environments* (pp. 60–62). Cambridge university press.
- Menoyo Ros, D., Garcia Lopez, E., & Garcia Cabot, A. (2021). *Fundamentos de la ciencia de datos*. Editorial Universidad de Alcala. <https://elibro.net/es/lc/unad/titulos/177631>
- Ministerio de Minas y Energía. (2024). *Libro 1—Disposiciones Generales* (Reglamento Técnico de Instalaciones Eléctricas - RETIE, p. 3).  
<https://www.minenergia.gov.co/es/misional/energia-electrica-2/reglamentos-tecnicos/reglamento-t%C3%A9cnico-de-instalaciones-el%C3%A9ctricas-reetie/>
- Myers, D. R. (2013). *Solar Radiation: Practical Modeling for Renewable Energy Applications* (1st ed). Taylor & Francis Group.

- Phiri, M., Mulenga, M., Zimba, A., & Eke, C. I. (2023). Deep learning techniques for solar tracking systems: A systematic literature review, research challenges, and open research directions. *Solar Energy*, 262, 111803. <https://doi.org/10.1016/j.solener.2023.111803>
- Rodriguez Muinos, C., Sanchez Lasheras, F., & Menendez Garcia, L. A. (2022). *Sistemas de aprendizaje automatico*. Marcombo.  
<https://elibro-net.bibliotecavirtual.unad.edu.co/es/ereader/unad/280359?page=27>
- Rodriguez-Gallegos, C. D., Gandhi, O., Panda, S. K., & Reindl, T. (2020). On the PV Tracker Performance: Tracking the Sun Versus Tracking the Best Orientation. *IEEE Journal of Photovoltaics, Photovoltaics, IEEE Journal of, IEEE J. Photovoltaics*, 10(5), 1474–1480. IEEE Xplore Digital Library (edsee.9139448).  
<https://doi.org/10.1109/JPHOTOV.2020.3006994>
- Sadeghi, R., Parenti, M., Memme, S., Fossa, M., & Morchio, S. (2025). A Review and Comparative Analysis of Solar Tracking Systems. *Energies (19961073)*, 18(10), 2553. Academic Search Ultimate (185477243). <https://doi.org/10.3390/en18102553>
- Santos de Araújo, J. V., de Lucena, M. P., da Silva Netto, A. V., Gomes, F. da S. V., Oliveira, K. C. de, de Souza Neto, J. M. R., Cavalcante, S. L., Morales, L. R. V., Villanueva, J. M. M., & Macedo, E. C. T. de. (2024). Solar Tracking Control Algorithm Based on Artificial Intelligence Applied to Large-Scale Bifacial Photovoltaic Power Plants. *Sensors (14248220)*, 24(12), 3890. Academic Search Ultimate. <https://doi.org/10.3390/s24123890>
- UL Solutions. (2025). *Solar tracking*. PV Mounting Systems Certification.  
<https://www.ul.com/services/pv-mounting-systems-certification>
- Vignola, F. (with Michalsky, J., & Stoffel, T. L.). (2019). *Solar and infrared radiation measurements, Second Edition*. CRC PRESS.

Zippenfenig, P. (2024). *Open-Meteo.com Weather API* (Versión 1.4.0) [Software]. Zenodo.

<https://doi.org/10.5281/ZENODO.7970649>

## Apéndices

### Apéndice A

#### *Sección del Código de Programación del Arduino UNO R4 Wifi*

```
// Lectura de sensores

if (ahora - LastTime >= 100) {

    lastTime = ahora;

    conteoLecturas++;

    lecturaAngulos();

    // Leer datos del acelerómetro (6 bytes: ax, ay, az 2 bytes cada uno)

    Wire.beginTransmission(BMI160_I2C_ADDRESS);

    Wire.write(0x12); // Registro de inicio para datos acelerómetro

    Wire.endTransmission(false);

    Wire.requestFrom(BMI160_I2C_ADDRESS, 6);

    if (Wire.available() == 6) {

        ax = (Wire.read() | (Wire.read() << 8));

        ay = (Wire.read() | (Wire.read() << 8));

        az = (Wire.read() | (Wire.read() << 8));}

    // Convertir valores raw a g

    float ax_g = (float)ax / ACCEL_SENSITIVITY;

    float ay_g = (float)ay / ACCEL_SENSITIVITY;

    float az_g = (float)az / ACCEL_SENSITIVITY;

    // Calcular ángulos Pitch y Roll en grados

    //anguloEO = atan2(ay_g, sqrt(ax_g * ax_g + az_g * az_g)) * 180.0 / PI;
```

```
anguloEO = atan2(-ax_g, az_g) * 180.0 / PI;
anguloNS = encoder2.readAngle()*0.087890625;
// Control sencillo
error1 = calcularErrorAngular(setpoint_EO, anguloEO);
if (abs(error1) > 2) {
    moverMotor(RPWM1, LPWM1, (error1 > 0) ? 1 : -1);
} else {
    moverMotor(RPWM1, LPWM1, 0);
}
error2 = calcularErrorAngular(setpoint_NS, anguloNS);
if (abs(error2) > 1.5) {
    moverMotor(RPWM2, LPWM2, (error2 > 0) ? 1 : -1);
} else {
    moverMotor(RPWM2, LPWM2, 0);
}
medicion_energia();}
```

## Apéndice B

*Sección del Código en Python para el Calculo de la Posición del Panel Según el Modelo de Machine Learning*

```
def ejecutar_periodicamente(self):
    while True:
        ahora = datetime.now(tz=zona_horaria)

        minuto_actual = ahora.minute

        # Calcula el próximo múltiplo de 15
        minutos_hasta_proximo = 15 - (minuto_actual % 15)

        proxima = ahora.replace(second=0, microsecond=0) +
timedelta(minutes=minutos_hasta_proximo)

        # Espera hasta la próxima ejecución
        espera = (proxima - ahora).total_seconds()

        if espera > 0:
            time.sleep(espera)

        hora = pd.Timestamp.now(tz=tz)

        self.meteorologia()

        solpos = solarposition.get_solarposition(hora, latitude, longitude, altitude,
                                                pressure=self.current_surface_pressure,
temperature=self.current_temperature_2m)

        print(solpos)

        if solpos.iloc[0]['apparent_zenith'] < 90 and self.current_wind_speed_10m < 50:
```

```

irradiancia = self.minutely_15_dataframe.iloc[(self.minutely_15_dataframe['date'] -
ahora).abs().argsort()[:1]]

hora_decimal = irradiancia['date'].dt.hour + irradiancia['date'].dt.minute/60

X = irradiancia.copy()

X['zenith_solar'] = solpos['apparent_zenith'].values

X['azimuth_solar'] = solpos['azimuth'].values

X['Wind_Direction'] = self.current_wind_direction_10m

X['Temperature'] = self.current_temperature_2m

X['Relative_Humidity'] = self.current_relative_humidity_2m

X['sin_hora'] = np.sin(2 * np.pi * hora_decimal / 24)

X['hora_decimal'] = hora_decimal

tilt_pred = tilt_model.predict(X[tilt_features])

azimuth_pred = azimuth_model.predict(X[azimuth_features])

print(f"Acimut: {azimuth_pred[0]} Cenit: {tilt_pred[0]}")

solpos_acimut = math.radians(azimuth_pred[0] - 43)

solpos_cenit = math.radians(tilt_pred[0])

x = math.sin(solpos_cenit) * math.sin(solpos_acimut)

y = math.sin(solpos_cenit) * math.cos(solpos_acimut)

z = math.cos(solpos_cenit)

angulo_EO = math.degrees(math.atan(x/z))

angulo_NS = math.degrees(math.asin(-y))

angulo_EO = max(-55, min(angulo_EO, 55))

angulo_NS = max(-38, min(angulo_NS, 38))

```

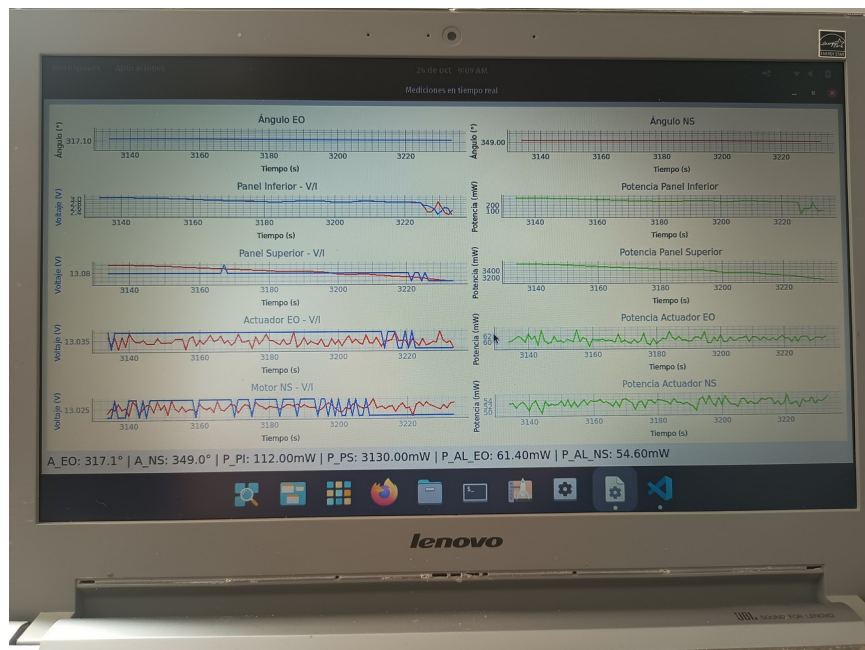
```
else:  
    angulo_EO = 0  
    angulo_NS = 0  
    mensaje = f"{angulo_EO};{angulo_NS}\n"  
    self.arduino.write(mensaje.encode())  
    fecha_actual = hora.strftime("%Y-%m-%d")  
    hora_actual = hora.strftime("%H:%M")  
    print(f"[{fecha_actual} {hora_actual}] Enviado: {mensaje.strip()}")
```

## Apéndice C

### Registro Fotográfico

#### Figura 21


#### Pantalla de Registro de Mediciones en el Día 26/10/2025



*Nota.* Computador portátil que muestra las mediciones en tiempo real capturadas con los sensores.

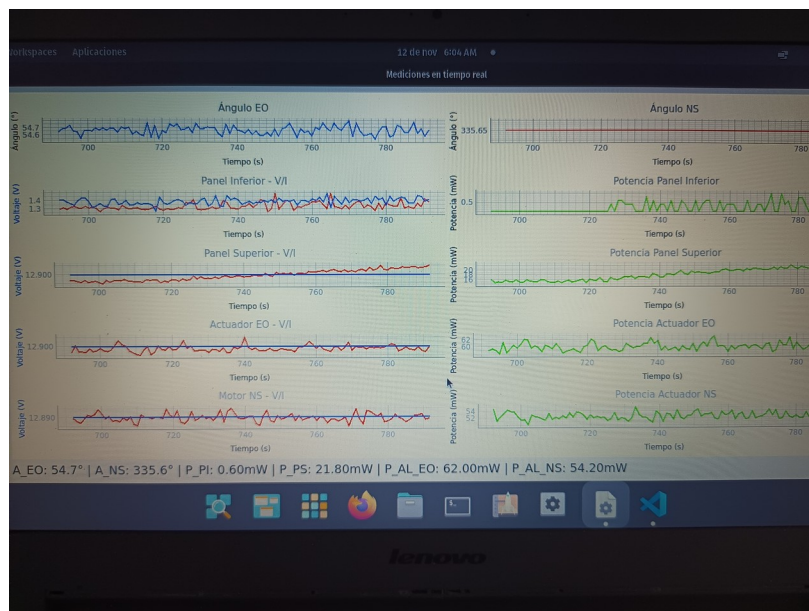
**Figura 22**

*Seguidor Solar Bajo Condiciones de Nubosidad*



**Figura 23**

*Pantalla de Mediciones el Día 12/11/2025*



## Apéndice D

### Presupuesto del Seguidor Solar de 1200W

**Tabla 3**

#### Costos de Estructura y Componentes Generales del Seguidor Solar de 1200W

Artículo	Costo	Cantidad	Subtotal
Tubo cuadrado acero	\$119,000.00	1	\$119,000.00
Soporte estructura	\$36,000.00	1	\$36,000.00
Pintura anticorrosiva	\$41,000.00	1	\$41,000.00
Union Bisagra	\$48,000.00	3	\$144,000.00
Tornillo M6 inoxidable	\$1,000.00	20	\$20,000.00
Pernos anclaje metalico	\$7,500.00	6	\$45,000.00
Tuerca M6 inoxidable	\$925.00	20	\$18,500.00
Arandela M6 inoxidable	\$2,000.00	20	\$40,000.00
Soldadura de estructura	\$150,000.00	1	\$150,000.00
Driver puente H	\$42,000.00	2	\$84,000.00
Encoder Incremental 600	\$60,000.00	2	\$120,000.00
Actuador 12V 300Kg	\$145,000.00	2	\$290,000.00
Controlador de Carga MPPT	\$245,000.00	1	\$245,000.00
Batería 12V 250Ah	\$1,380,000.00	1	\$1,380,000.00
Cable AWG 6	\$12,600.00	6	\$75,600.00
Inversor	\$560,000.00	1	\$560,000.00
Protecciones	\$450,000.00	1	\$450,000.00
Panel solar	\$580,000.00	2	\$1,160,000.00
Regulador de voltaje	\$28,000.00	1	\$28,000.00
Cable AWG 20	\$1,500.00	10	\$15,000.00
Cimentación en concreto	\$160,000.00	1	\$160,000.00
			<b>\$5,181,100.00</b>

*Nota.* Valores obtenidos de tiendas en línea presentes en Colombia a la fecha del documento.