

# ESTIMACIÓN DE POTENCIA ACTIVA DE SISTEMAS FOTOVOLTAICOS: CONSIDERANDO EL EFECTO DEL CLIPPING Y SEGMENTACIÓN HORARIA

## ACTIVE POWER ESTIMATION OF PHOTOVOLTAIC SYSTEMS: CONSIDERING THE CLIPPING EFFECT AND TEMPORAL SEGMENTATION

**Juliana Valencia Vélez<sup>1</sup>, Rafaela Elenia Quintero Rocha<sup>2</sup>, Felipe Sánchez Londoño<sup>3</sup>,  
Santiago Benavides Cordoba<sup>4</sup>.**

**Resumen:** La estimación precisa de la potencia de salida de inversores solares es esencial para optimizar la operación de sistemas de generación fotovoltaica. Sin embargo, los modelos tradicionales no consideran efectos operativos como el *clipping* (que ocurre cuando la potencia generada excede la capacidad nominal del inversor), lo que conduce a desviaciones en la estimación. Este estudio propone un enfoque de modelado que incorpora este efecto y emplea datos experimentales adquiridos cada 20 segundos de una instalación solar de 20 kW. Se utilizó un modelo de regresión lineal múltiple, considerando etapas de limpieza de datos y segmentación temporal. Los resultados muestran una mejora significativa en la precisión del modelo, especialmente al dividir los datos en períodos de mañana y tarde. Este trabajo sienta las bases para desarrollar aplicaciones futuras como el mantenimiento predictivo mediante la implementación de un gemelo digital de la instalación.

---

<sup>1</sup> Estudiante de ingeniería eléctrica, Universidad de Antioquia, Colombia, Medellín.  
Correo electrónico: juliana.valenciacv@udea.edu.co

<sup>2</sup> Estudiante de ingeniería eléctrica, Universidad de Antioquia, Colombia, Medellín.  
Correo electrónico: rafaela.quintero@udea.edu.co

<sup>3</sup> Estudiante de ingeniería eléctrica, Universidad de Antioquia, Colombia, Medellín.  
Correo electrónico: felipe.sanchez1@udea.edu.co

<sup>4</sup> PhD en ingeniería eléctrica, Universidad de Antioquia, Colombia, Medellín.  
Investigador posdoctoral. Correo electrónico: santiago.benavides@udea.edu.co

**Palabras clave:** Sistemas fotovoltaicos, estimación de potencia, clipping, MPPT, regresión lineal, modelado físico, limpieza de datos, segmentación horaria, energía solar, eficiencia operativa.

**Abstract:** Accurate estimation of the output power of solar inverters is essential to optimize the operation of photovoltaic generation systems. However, traditional models do not account for operational effects such as clipping—occurring when the generated power exceeds the inverter's nominal capacity—nor the voltage constraints imposed by the MPPT algorithm, leading to deviations in estimation. This study proposes a modeling approach that incorporates both effects and uses experimental data acquired every 20 seconds from a 20 kW solar installation. A multiple linear regression model was employed, including data cleaning and temporal segmentation steps. The results show a significant improvement in model accuracy, particularly when splitting the data into morning and afternoon periods. This work lays the groundwork for future applications such as predictive maintenance through the implementation of a digital twin of the installation.

**Keywords:** Photovoltaic systems, power estimation, clipping, MPPT, multiple linear regression, physical modeling, data cleaning, temporal segmentation, solar energy, operational efficiency.

## 1. Introducción

La generación de energía fotovoltaica ha experimentado un crecimiento significativo en las últimas décadas, consolidándose como una tecnología clave para sistemas energéticos sostenibles [1]. Este auge ha sido impulsado por la necesidad de reducir las emisiones de gases de efecto invernadero y la dependencia de combustibles fósiles. Además, los avances en materiales, eficiencia de conversión y reducción de costos han fortalecido su adopción global. En particular, se proyecta que la energía solar se convierta en la fuente de energía dominante en el futuro

cercano, respaldada por políticas energéticas favorables y metas de descarbonización a nivel mundial [2].

A pesar de su rápida expansión, uno de los desafíos fundamentales en el desarrollo y operación de sistemas fotovoltaicos es la capacidad de estimar con precisión la potencia eléctrica generada bajo condiciones ambientales reales [3]. Esta estimación es esencial para la integración eficiente de estos sistemas en la red eléctrica y para la planificación de recursos energéticos. La falta de precisión puede conllevar pérdidas económicas, decisiones subóptimas de dimensionamiento o una mala evaluación del estado de funcionamiento del sistema.

Esta estimación es crítica para la planificación energética y la maximización del rendimiento del sistema. Sin embargo, los modelos tradicionales a menudo simplifican o ignoran fenómenos operativos clave, como el clipping del inversor (cuando la potencia generada excede su capacidad nominal) y las dinámicas del algoritmo de seguimiento del punto de máxima potencia (MPPT) [4,5].

A lo largo de los años, los modelos fotovoltaicos han evolucionado desde representaciones simplificadas como el modelo de un solo diodo [6], hasta modelos más complejos como el de dos diodos, capaces de capturar con mayor fidelidad fenómenos como la recombinación interna, especialmente bajo condiciones de baja irradiancia y altas temperaturas [8]. También se han propuesto enfoques computacionalmente eficientes que permiten simular grandes sistemas, utilizando relaciones analíticas entre los parámetros eléctricos y ambientales [7,8]. En cuanto al modelado del inversor, se han desarrollado esquemas basados en regresión lineal y arquitecturas de conversión en dos etapas (DC/DC y DC/AC), que consideran funciones específicas de control [9]. No obstante, estos trabajos, aunque valiosos, no consideran restricciones operativas críticas como el clipping del inversor ni las dinámicas del MPPT, ambos determinantes para la eficiencia global del sistema.

Estudios recientes han abordado por separado estos fenómenos. En [4], se cuantifican las pérdidas energéticas causadas por clipping, destacando su impacto en instalaciones con sobredimensionamiento del campo solar, y [5] muestra cómo el uso de datos de alta resolución mejora la estimación de estas pérdidas. Por otro lado, investigaciones como [10] han desarrollado algoritmos de MPPT basados en modelos físicos detallados para mejorar su precisión, y en [11] se proponen enfoques híbridos que combinan técnicas de control avanzado con modelado predictivo. Sin embargo, aún no se ha propuesto un modelo matemático unificado que integre de forma explícita tanto el efecto del clipping como las restricciones dinámicas del MPPT. Esta investigación propone precisamente ese enfoque, permitiendo una estimación más realista y precisa de la potencia entregada por el inversor bajo condiciones reales de operación. Esta integración representa el principal aporte y novedad de este trabajo.

Este artículo se estructura de la siguiente manera: la sección 2 describe los materiales y métodos, incluyendo el preprocesamiento de datos y la metodología de modelado; la sección 3 presenta los resultados obtenidos y su análisis comparativo; la sección 4 discute los hallazgos y sus implicaciones; la sección 5 expone las conclusiones y propuestas para trabajo futuro.

## 2. Materiales y Métodos

El modelado del inversor tiene como variables de entrada la irradiancia, medida en vatios por metro cuadrado ( $\text{W/m}^2$ ) y la temperatura, registrada en grados Celsius ( $^{\circ}\text{C}$ ) y como salida, la potencia generada por el inversor, en (W). No obstante, es necesario considerar ciertas condiciones que pueden afectar la calidad de los datos, como la inclinación del sistema fotovoltaico, las limitaciones de potencia impuestas por el inversor, errores de captura, y eventos de desconexión momentánea provocados por el inversor para verificar el estado de los paneles solares. La forma de abordar el modelamiento de este sistema es

utilizando regresiones lineales considerando los fenómenos físicos que presentan los inversores.


El procedimiento que se realiza para el modelado se describe en seis etapas:

- Visualización de datos para análisis del sistema.
- Eliminación de datos por recorte de potencia.
- Eliminación de datos por funcionamiento del inversor.
- Eliminación de datos atípicos.
- Segmentación de datos por tiempo.
- Desarrollo del modelo por regresión lineal.

## 2.1. Visualización de datos para análisis del sistema

La visualización de datos es el primer paso para modelar usando regresión lineal. La literatura describe una relación entre potencia, irradiancia y temperatura, y el primer paso es ver visualmente el comportamiento entre las variables.

Estos datos particulares se ilustran en la figura 1 dentro de los recuadros rojos, así entonces es posible identificar esas anomalías y patrones que justifican la necesidad de una depuración cuidadosa de los datos antes de su utilización en el proceso de modelado.




**Figura 1.** Muestreo de datos atípicos del día 14-04-2025.

**Fuente:** Elaboración propia.

Dado que estos fenómenos introducen sesgos en los registros, es esencial su identificación y eliminación para asegurar la integridad de los datos y optimizar el desempeño del modelo.

## 2.2. Eliminación de datos por recorte de potencia

Los inversores de sistemas solares fotovoltaicos están programados con una función de recorte de potencia para evitar que la potencia de salida exceda su capacidad nominal. Este fenómeno ocurre cuando la potencia del arreglo fotovoltaico ha sido sobredimensionada respecto a la potencia de salida del inversor. Esta práctica es común para optimizar el aprovechamiento del espacio y maximizar la generación energética durante las horas de mayor irradiancia [12]. En este trabajo se utiliza un inversor de una potencia máxima nominal de 10 kW, por lo que realiza *clipping* o recorte cuando la potencia disponible en paneles por irradiancia es mayor que la potencia que puede entregar el inversor. En la figura 2 se evidencia el efecto del *clipping* del inversor mostrando, dentro del recuadro rojo, que la potencia máxima es de 10 kW aunque la irradiancia siga aumentando.



**Figura 2.** Efecto del clipping en los datos del día 13-02-2025.


**Fuente:** Elaboración propia.

En los sistemas solares generalmente se sobredimensiona la potencia de entrada respecto a la salida para aprovechar más la energía irradiada por el sol, considerando que la potencia máxima entregada por el sol ocurre solamente una vez al día durante poco tiempo. Cuando se presenta este fenómeno, los datos de potencia dejan de mantener una correlación lineal con la irradiancia y temperatura, ya que interviene la limitación impuesta por el inversor. Por ello, al modelar la potencia estimada en función de la irradiancia, es necesario restringir el valor máximo a la potencia nominal del inversor (10 kW), de modo que el modelo no arroje estimaciones superiores a lo que realmente puede entregar el sistema.

### **2.3. Eliminación de datos por pruebas automáticas de detección de arco en el inversor**

En sistemas fotovoltaicos conectados a inversores modernos, es común la incorporación de mecanismos de protección avanzados como el AFCI (Arc Fault Circuit Interrupter). Este sistema tiene como propósito identificar la presencia de fallas por arco eléctrico en el lado de corriente continua (DC), las cuales pueden representar un riesgo de incendio o deterioro del sistema. La detección se basa en el análisis de perturbaciones de alta frecuencia en las curvas de corriente y voltaje, mediante algoritmos electrónicos embebidos en el inversor [13].

En el caso específico del inversor Fronius Symo 10.0-3-M, cuando se detecta un posible arco voltaico, el equipo interrumpe automáticamente la entrega de potencia a la red, llevando el sistema a condiciones de potencia generada igual a cero, incluso si la irradiancia es suficiente para la generación. Este fenómeno puede durar varios minutos mientras se verifica el estado del sistema o se restablece automáticamente la operación.



**Figura 3.** Efecto de la función de protección AFCI del día 23-05-2025.

**Fuente:** Elaboración propia.


El mecanismo de protección AFCI al reflejarse en los registros como datos de generación nula sin causas meteorológicas o de sombreado justificables, fueron considerados como datos atípicos dentro del análisis. Por tanto, se eliminaron del conjunto de entrenamiento y validación del modelo predictivo para evitar distorsiones en el desempeño del modelo.

#### 2.4. Eliminación de datos atípicos

Durante la adquisición de datos, además de los fenómenos físicos conocidos que pueden afectar las mediciones, pueden ocurrir fallos en el registro que generan datos atípicos evidentes. Estos valores anómalos pueden deberse a errores de medición, registros incompletos, condiciones climáticas inusuales como la presencia repentina de nubes, la medida errónea durante el recorte de potencia o respuestas no esperadas del sistema fotovoltaico.

La presencia de estos datos altera los resultados del análisis y afecta el desempeño de los modelos predictivos, por lo que su identificación y eliminación es necesaria. Para este estudio, se aplicó el método del rango intercuartílico (IQR) sobre la relación Fronius/Irradiancia, con el objetivo de detectar valores atípicos. Se utilizó un factor de 1.5 para establecer los límites inferior y

superior aceptables, eliminando aquellos datos que se encontraban fuera de este rango. Este enfoque estadístico permitió limpiar el conjunto de datos conservando únicamente las observaciones representativas del comportamiento real del sistema [14].



**Figura 4.** Muestreo de datos atípicos del día 21-05-2025.


**Fuente:** Elaboración propia.

## 2.5. Segmentación temporal

Los datos se dividieron en dos períodos para capturar las diferentes características de generación solar: período de mañana (06:00 a 12:00 horas) y período de tarde (12:01 a 18:00 horas). Esta segmentación permitió entrenar modelos específicos para cada período del día. Esta segmentación se realiza porque en el modelado realizado, se notaba una leve diferencia.

## 2.6. Desarrollo del modelo

El modelado del sistema potencia-irradiancia-temperatura se realiza utilizando regresión lineal múltiple. La metodología utilizada se muestra en la figura 5:



**Figura 5.** Diagrama de flujo de la metodología.

**Fuente:** Elaboración propia.

### 3. Resultados

#### 3.1. Descripción de la instalación solar

Los datos utilizados para este estudio fueron obtenidos de una instalación solar fotovoltaica real de 20 kW de potencia nominal instalada en una sede de la Universidad de Antioquia, ubicada en El Carmen de Viboral, Antioquia, Colombia. La instalación incluye un conjunto de 66 paneles solares, cada panel con una potencia pico de 315~W, distribuidos entre diferentes tipos de inversores: 33 paneles están conectados a un inversor trifásico Fronius Symo Advanced de 10~kW, tres inversores monofásicos Victron Quattro, cada uno de 5~kW, configurados en un banco trifásico este sistema cuenta con un banco de cuatro baterías Pylontech conectadas en serie con una capacidad conjunta de 14~kWh las cuales están conectadas a 3 paneles, lo que permite el almacenamiento y gestión energética local. Además, hay 27 microinversores Enphase iQ7+ y se usaron sensores de irradiancia y temperatura con muestreo cada 20 segundos. La instalación

opera bajo condiciones reales, lo que permitió capturar comportamientos operativos relevantes como el clipping y eventos de desconexión.

### 3.2. Evaluación del modelo con diferentes condiciones de preprocesamiento

El modelo fue evaluado bajo tres condiciones distintas:

#### 3.2.1. Modelo sin preprocesamiento de datos


Se utilizó la base completa sin eliminar datos atípicos ni recorte por clipping. El resultado se muestra en las figuras 1, 2, 3 y 4. Al aplicar una regresión lineal múltiple a todos los datos sin preprocesamiento, se obtuvo el siguiente modelo:

$$P = 7,5676 \cdot G + 9,6409 \cdot T + 87,2590 \quad (1)$$

El coeficiente de correlación promedio fue  $R^2 = 0,649$ , reflejando una correlación moderada entre las variables irradiancia, temperatura y potencia.


#### 3.2.2. Modelo con preprocesamiento de datos

Se eliminaron datos atípicos, registros con potencia igual a cero sin causa meteorológica aparente, y se aplicó el filtro por clipping.




**Figura 6.** Potencia real y estimada vs irradiancia del día 14-04-2025 con preprocesamiento.

**Fuente:** Elaboración propia.




**Figura 7.** Potencia real y estimada vs irradiancia del día 13-02-2025 con preprocesamiento.

**Fuente:** Elaboración propia.



**Figura 8.** Potencia real y estimada vs irradiancia del día 23-05-2025 con preprocesamiento.

**Fuente:** Elaboración propia.



**Figura 9.** Potencia real y estimada vs irradiancia del día 21-05-2025 con preprocesamiento.

**Fuente:** Elaboración propia.

Tras eliminar registros atípicos, datos con potencia igual a cero sin causa meteorológica evidente y aplicar filtros por clipping, se obtuvo una mejora considerable en el ajuste del modelo. La regresión lineal múltiple dio como resultado el siguiente modelo:

$$P = 8,6369 \cdot G - 46,6232 \cdot T + 1259,4422 \quad (2)$$

Esta depuración condujo a un coeficiente de correlación superior, alcanzando un promedio de  $R^2 = 0,945$ , lo cual sugiere una relación más sólida y representativa entre las variables bajo condiciones más controladas.

### 3.2.3. Modelo con preprocesamiento y segmentación temporal:

Además de la limpieza, los datos fueron segmentados en periodo de mañana (06:00 a 12:00) y tarde (12:01 a 18:00), para evaluar mejoras en la correlación y precisión del modelo. Los resultados a continuación evidencian que la segmentación horaria del día en periodos de mañana y tarde mejora significativamente la capacidad del modelo para estimar la potencia, al adaptarse mejor a los patrones dinámicos de irradiancia y temperatura en cada intervalo.

Con el objetivo de mejorar la precisión del modelo, se optó por dividir el día en dos períodos: mañana (06:00–12:00) y tarde (12:01–18:00). Esta segmentación permite capturar mejor los patrones horarios de la producción fotovoltaica, resultando en los siguientes modelos:

En la franja horaria de la mañana:

$$P = 8,2781 \cdot G + 5,4797 \cdot T + 340,9266 \quad (3)$$

Con un coeficiente de correlación promedio de  $R^2 = 0,990$ , lo que representa una mejora significativa en la capacidad predictiva del modelo.

En la franja horaria de la tarde:

$$P = 7,5433 \cdot G + 50,2032 \cdot T - 694,5408 \quad (4)$$

Este modelo alcanzó un promedio de  $R^2 = 0,986$ , confirmando también en la tarde una alta correlación entre las variables.

La notable mejora en los valores de  $R^2$  tras la segmentación temporal evidencia que dividir el modelo en franjas horarias permite capturar mejor las dinámicas físicas del sistema, y por tanto, se justifica su implementación como estrategia de optimización del ajuste y la precisión del modelo.

### 3.3. Desempeño del modelo

La precisión del modelo fue evaluada utilizando el coeficiente de determinación  $R^2$  observando mejoras sustanciales en la estimación de la potencia a medida que se incorporaban técnicas de limpieza y segmentación. A continuación, se resumen los valores obtenidos:

Fecha	Sin preprocesamiento	Con preprocesamiento	Con segmentación y preprocesamiento
06-06-2025	0,8899	0,9853	0,9907
11-06-2025	0,9418	0,9851	0,9894
12-06-2025	0,9779	0,9699	0,9755


**Tabla 1.** Comparación del coeficiente de correlación  $R^2$  para diferentes modelos de estimación de potencia.

**Fuente:** Elaboración propia.

Estas cifras muestran que la segmentación temporal mejora ligeramente la correlación entre las variables de entrada (irradiancia y temperatura) y la potencia estimada, lo cual respalda la validez de un modelo diferenciado por franjas horarias.


### 3.4. Visualización de resultados

A continuación, se presentan visualizaciones comparativas que ilustran el desempeño del modelo de regresión lineal múltiple bajo tres enfoques metodológicos: Sin preprocesamiento de datos, con limpieza de datos, y con segmentación horaria (mañana y tarde). Estas gráficas permiten observar de forma cualitativa cómo el preprocesamiento y la segmentación impactan la capacidad del modelo para estimar adecuadamente la potencia generada, a partir de las variables meteorológicas. El objetivo es evidenciar visualmente las mejoras progresivas en la correlación entre los valores estimados y los valores reales conforme se aplican técnicas adicionales de tratamiento de datos.



**Figura 10.** Comparación entre la potencia estimada y real bajo del día 06-06-2025 diferentes condiciones: a) Sin preprocesamiento, b) con preprocesamiento y c) con modelo segmentado.

**Fuente:** Elaboración propia.



**Figura 11.** Comparación entre la potencia estimada y real bajo del día 11-06-2025 diferentes condiciones: a) Sin preprocessamiento, b) con preprocessamiento y c) con modelo segmentado.

**Fuente:** Elaboración propia.

Como puede observarse en las figuras, la estimación de potencia mejora notablemente con la inclusión de estrategias de preprocessamiento, especialmente la eliminación de datos atípicos y el filtrado por clipping. Sin embargo, el mayor aumento en la precisión del modelo se obtiene al implementar la segmentación horaria, lo cual permite capturar dinámicas particulares del comportamiento fotovoltaico durante la mañana y la tarde. Esta segmentación facilita un ajuste más específico de los coeficientes del modelo, incrementando de forma significativa la capacidad predictiva del sistema.

### 3.5. Síntesis de resultados

Los resultados muestran que el proceso de limpieza de datos mejora notablemente la precisión del modelo, y que la segmentación en franjas horarias incrementa aún más la correlación. Esto

sugiere que un enfoque de modelado adaptativo en función del horario puede ser una estrategia eficaz para aumentar la fidelidad en la estimación de la potencia solar.

#### **4. Discusión**

Los resultados obtenidos confirman que la incorporación explícita de las restricciones operativas del inversor —específicamente el clipping—, junto con una adecuada segmentación horaria y la limpieza estadística de datos, conduce a mejoras significativas en la estimación de potencia.

Se observó que el modelo sin segmentación presenta una dispersión mayor en los errores, atribuible a la variabilidad térmica a lo largo del día. En cambio, al separar los datos por franjas horarias, se obtuvo un comportamiento más homogéneo, con mejor ajuste en ambos períodos. Adicionalmente, la eliminación de eventos no representativos —como pruebas automáticas del inversor o datos nulos causados por desconexiones breves— demostró ser clave para evitar distorsiones en la regresión. Esto sugiere que, para modelos de estimación basados en variables ambientales, el tratamiento riguroso de datos es tan importante como el algoritmo matemático.

#### **5. Conclusiones**

Este estudio propuso un modelo de estimación de potencia para sistemas fotovoltaicos que incorpora restricciones físicas derivadas del comportamiento real del inversor. Al integrar los efectos del clipping y las limitaciones dinámicas impuestas por el MPPT, el modelo alcanza un nivel de realismo superior a los enfoques tradicionales.

El uso de regresión lineal múltiple, acompañado de técnicas de limpieza de datos, eliminación de atípicos y segmentación temporal, permitió obtener un alto coeficiente de correlación entre la potencia estimada y la medida, validando la eficacia del enfoque propuesto.

#### **6. Abreviaturas**

En este artículo se utilizaron las siguientes abreviaturas:

PV: Fotovoltaico (Photovoltaic)

DC: Corriente continua (Direct Current)

AC: Corriente alterna (Alternating Current)

IQR: Rango intercuartílico (Interquartile Range)

AFCI: Interruptor de falla por arco eléctrico (Arc Fault Circuit Interrupter)

R<sup>2</sup>: Coeficiente de determinación (Coeficiente R cuadrado)

kW: Kilovatio

W: Vatio

W/m<sup>2</sup>: Vatios por metro cuadrado

## **Reconocimientos**

Se agradece el esfuerzo y el patrocinio del grupo de investigación del manejo eficiente de la energía eléctrica (GIMEL) por permitirnos realizar el estudio hecho en este artículo con los datos recolectados de la microred de la Universidad de Antioquia ubicada en su sede del Carmen de Viboral.

## **Referencias**

- [1] A. Shukla, A. Kumar, P. Jain, R. Bansal, and M. Gupta, "Advancements and challenges in solar photovoltaic technologies," *Sustainable Energy Technologies and Assessments*, vol. 61, p. 103969, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2667113124000342>
- [2] R. Joshi, B. Sharma, S. Das, and A. Kumar, "A comprehensive review on solar photovoltaics," *Solar Energy Advances*, vol. 5, p. 100082, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2772737825000070>

- [3] T. Ma, H. Yang, and L. Lu, "Solar photovoltaic system modeling and performance prediction," *Renewable and Sustainable Energy Reviews*, vol. 36, pp. 304–315, 2014.
- [4] M. Bakhtiari, A. Khodayar, R. Iravani, and M. H. Rehmani, "Quantifying the impact of inverter clipping on photovoltaic performance," *Renewable Energy*, vol. 215, 2024. [Online].  
Available: <https://www.sciencedirect.com/science/article/pii/S0960148124003823>
- [5] R. Sharma, V. Jain, and A. Singh, "Influence of high-resolution data on accurate curtailment loss estimation in photovoltaic systems," *Applied Energy*, vol. 370, 2024. [Online].  
Available: <https://www.sciencedirect.com/science/article/pii/S030626192401167X>
- [6] M. G. Villalva, J. R. Gazoli, and E. R. Filho, "Comprehensive approach to modeling and simulation of photovoltaic arrays," *IEEE Transactions on Power Electronics*, vol. 24, no. 5, pp. 1198–1208, 2009. [Online].  
Available: <https://ieeexplore-ieee-org.udea.lookproxy.com/document/4806084>
- [7] W. Xiao, F. F. Edwin, G. Spagnuolo, and J. Jatskevich, "Efficient approaches for modeling and simulating photovoltaic power systems," *IEEE Journal of Photovoltaics*, vol. 3, no. 1, pp. 500–508, 2013. [Online].  
Available: [https://www.researchgate.net/publication/260708697\\_Efficient\\_Approaches\\_for\\_Modeling\\_and\\_Simulating\\_Photovoltaic\\_Power\\_Systems](https://www.researchgate.net/publication/260708697_Efficient_Approaches_for_Modeling_and_Simulating_Photovoltaic_Power_Systems)
- [8] T. Ma, H. Yang, and L. Lu, "Solar photovoltaic system modeling and performance prediction," *Renewable and Sustainable Energy Reviews*, vol. 36, pp. 304–315, 2014. [Online].  
Available: <https://www.sciencedirect.com/science/article/abs/pii/S1364032114002950>
- [9] C.-Y. Park et al., "Inverter efficiency analysis model based on solar power estimation using solar radiation," *Processes*, vol. 8, no. 10, p. 1225, 2020. [Online].

Available: <https://www.mdpi.com/2227-9717/8/10/1225>

- [10] A. Hashemi, S. Tabrizi, M. H. Nehrir, and M. Saadat, "A model-based algorithm for maximum power point tracking of PV systems," *Solar Energy*, vol. 155, pp. 670–680, 2023. [Online].

Available: <https://www.sciencedirect.com/science/article/abs/pii/S0038092X17311362>

- [11] F. Kumar, N. Singh, and R. Verma, "Enhanced MPPT approach for grid-integrated solar PV system," *Materials Today: Proceedings*, 2024. [Online].

Available: <https://www.sciencedirect.com/science/article/pii/S235248472400605X>

- [12] K. Anderson and K. Perry, "Estimating subhourly inverter clipping loss from satellite-derived irradiance data," in *Proc. IEEE 47th Photovoltaic Specialists Conf. (PVSC)*, Calgary, AB, Canada, Jun.–Aug. 2020. [Online].

Available: <https://doi.org/10.1109/pvsc45281.2020.9300750>

- [13] Canal Solar, "Cada inversor tiene sistema AFCI," 2025. [Online].

Available: <https://canalsolar.com.br/es/Cada-inversor-tiene-sistema-AFCI/>

- [14] D. C. S. Kumar, A. K. Behera, S. Dehuri, and A. Ghosh, "An outliers detection and elimination framework in classification task of data mining," *Materials Today: Proceedings*, vol. 33, pp. 3821–3827, 2020. [Online].

Available: <https://doi.org/10.1016/j.matpr.2020.01.163>