



Universidad EAN

**Indicadores y métricas para la evaluación del rendimiento energético de sistemas
fotovoltaicos con inteligencia artificial aplicada al seguimiento solar: una revisión
descriptiva**

Seminario de investigación

Jaime Alberto Ochoa Durán

**Edwin Andrés Garzón Ordoñez
Michael Steven Gómez Collazos
Juan Camilo Montaña Ramírez
Paula Valentina Ospina Donado**

Tabla de Contenido

1.	Planteamiento del problema	4
2.	Pregunta de investigación	4
3.	Objetivos	5
3.1.	Objetivo General	5
3.2	Objetivos específicos	5
4.	Justificación	5
5.	Marco teórico	6
5.1	Energía solar y sistemas fotovoltaicos	6
5.2	Tipos de sistemas fotovoltaicos	6
5.3	Sistemas de seguimiento solar	7
5.4	Inteligencia artificial aplicada a sistemas fotovoltaicos	7
5.5	Variables climáticas y rendimiento energético	8
5.6	Indicadores de rendimiento energético	8
5.7	Métricas de evaluación de modelos de inteligencia artificial	9
6.	Diseño Metodológico	9
6.1	Enfoque, alcance y diseño de la investigación	9
6.2	Búsqueda bibliográfica	9
6.3	Matriz de revisión bibliográfica de estudios seleccionados	10
7.	Variables	19
7.1	Variables cualitativas	19
7.2	Variables cuantitativas	19
8.	Población y muestra	20
8.1	Población	20
8.2	Muestra	20
9.	Métodos e instrumentos de recolección de información	20
9.1	Métodos	20
9.2	Instrumentos	20
10.	Técnicas de análisis de información	20
11.	Consideraciones éticas	21
12.	Limitaciones del estudio	21
13.	Criterios de inclusión	22
14.	Criterios de exclusión	23

15.	Proceso de selección de estudios	23
16.	Técnicas de análisis de la información.....	24
16.1	Análisis cualitativo	24
16.2	Análisis cuantitativo	25
16.3	Síntesis comparativa	26
16.4	Identificación de categorías, variables y relaciones relevantes.....	26
16.5	Tabulación de hallazgos	28
17.	Conclusiones.....	38
	Referencias	40

1. Planteamiento del problema

El desarrollo de tecnologías de energías renovables ha impulsado la optimización de los sistemas fotovoltaicos con el fin de mejorar su eficiencia y confiabilidad en la generación de energía eléctrica. En este contexto, el uso de sistemas de seguimiento solar y la integración de modelos de inteligencia artificial han surgido como estrategias tecnológicas que permiten mejorar el aprovechamiento de la radiación solar y optimizar el desempeño energético de los paneles fotovoltaicos. Diversos estudios han demostrado que la aplicación de técnicas de machine learning y deep learning puede contribuir a mejorar la predicción de la radiación solar, la detección de fallas en los sistemas y la optimización del control operativo de las granjas solares (Mamodiya et al., 2025; Polymeropoulos et al., 2024). Asimismo, el uso de modelos inteligentes permite analizar grandes volúmenes de datos operativos lo que puede identificar patrones que influyen en el rendimiento del sistema y facilitar la toma de decisiones orientadas a mejorar la eficiencia energética (Salazar-Peña et al., 2024).

Sin embargo, a pesar del creciente interés por la aplicación de inteligencia artificial en sistemas fotovoltaicos, existe una amplia variedad de indicadores, métricas y métodos de evaluación utilizados para medir el rendimiento energético de estos sistemas. Diferentes investigaciones emplean diversos enfoques para evaluar la eficiencia, el desempeño operativo y la detección de fallas en paneles solares, lo que dificulta la comparación entre resultados y la identificación de las métricas más adecuadas para analizar el impacto de los modelos inteligentes en el seguimiento solar (Pa & Kazemi, 2022; Salazar-Peña et al., 2024). Según esto se puede evidenciar la necesidad de realizar una revisión descriptiva que permita identificar los principales modelos de inteligencia artificial que pueden ser utilizados para la predicción de radiación solar, describir los indicadores técnicos empleados para evaluar el rendimiento energético y comparar los métodos de evaluación reportados en la literatura científica sobre sistemas fotovoltaicos con inteligencia artificial aplicada para el seguimiento solar.

2. Pregunta de investigación

¿Cuáles son los principales indicadores, métricas y métodos de evaluación utilizados en la literatura científica para medir el rendimiento energético de sistemas fotovoltaicos que integran modelos de inteligencia artificial aplicados al seguimiento solar?

3. Objetivos

3.1. Objetivo General

Describir los principales indicadores y métricas utilizados en estudios científicos para medir el rendimiento energético de paneles solares con sistemas de inteligencia artificial aplicados al seguimiento solar.

3.2 Objetivos específicos

1. Identificar los modelos de inteligencia artificial reportados en la literatura para la predicción de radiación solar en sistemas fotovoltaicos.
2. Describir los indicadores técnicos utilizados para evaluar el desempeño energético de sistemas fotovoltaicos con integración de modelos predictivos.
3. Caracterizar los métodos de evaluación empleados en estudios previos en cuanto a su precisión y confiabilidad de los sistemas inteligentes aplicados al seguimiento solar.

4. Justificación

La amplia diversidad de métricas, horizontes temporales y estrategias de validación reportadas en la bibliografía especializada dificulta la comparación entre estudios y la selección de indicadores apropiados para aplicaciones operativas en sistemas fotovoltaicos con inteligencia artificial (Ahmed et al., 2020; Bamisile et al., 2022). Ante este escenario, el presente trabajo busca describir los principales indicadores y métricas utilizados según la literatura científica para evaluar el rendimiento energético de paneles solares con sistemas de inteligencia artificial aplicados para el seguimiento solar. Para ello, se propone identificar los modelos de IA empleados en la predicción de radiación solar, caracterizar los indicadores técnicos asociados al desempeño energético y comparar los métodos de evaluación que determinan la precisión y confiabilidad de dichos sistemas.

La sistematización de estos métodos resulta esencial para que tanto la comunidad científica como los actores industriales puedan evaluar de manera rigurosa la contribución real de los modelos inteligentes al incremento de la generación energética en sistemas con seguimiento solar. En este sentido, la literatura reciente destaca la importancia de la estandarización y conjuntos de referencia que faciliten la comparación del rendimiento predictivo entre distintos algoritmos y configuraciones experimentales (Barhmi et al., 2024). Por consiguiente, los objetivos planteados apuntan a generar una síntesis metodológica que favorezca la reproducibilidad, la

transferencia de resultados y la toma de decisiones técnico-operativas sustentadas en evidencia comparable.

5. Marco teórico

5.1 Energía solar y sistemas fotovoltaicos

La energía solar se ha consolidado como una de las principales fuentes renovables para la generación de electricidad a nivel mundial. Su aprovechamiento se basa en la conversión de la radiación solar en energía eléctrica mediante el efecto fotovoltaico, proceso que ocurre en las celdas solares que conforman los módulos fotovoltaicos. Esta tecnología ha adquirido una importancia creciente en el contexto de la transición energética global, debido a su capacidad para reducir las emisiones de gases de efecto invernadero y contribuir a sistemas energéticos más sostenibles (Ospino Castro et al., 2014; Vargas Sierra, 2025).

Los sistemas fotovoltaicos están compuestos por diversos elementos que permiten la captación, conversión y gestión de la energía solar. Entre los componentes principales se encuentran los módulos fotovoltaicos, que convierten la radiación solar en corriente eléctrica; los inversores, encargados de transformar la corriente continua en corriente alterna; y los sistemas de control que optimizan el funcionamiento del sistema. En algunos casos también se incluyen sistemas de almacenamiento energético y estructuras de soporte que permiten la correcta orientación de los paneles solares.

El rendimiento energético de los sistemas fotovoltaicos depende de múltiples factores, entre ellos la radiación solar disponible, la temperatura ambiente, la orientación e inclinación de los paneles, así como condiciones ambientales como el sombreado, la suciedad acumulada en los módulos o la velocidad del viento. Estos factores influyen directamente en la capacidad del sistema para convertir la energía solar en electricidad útil (Ayala Villacis, 2018; Duarte et al, 2022).

5.2 Tipos de sistemas fotovoltaicos

Asimismo, los sistemas fotovoltaicos pueden clasificarse en tres grandes categorías: sistemas conectados a la red, sistemas aislados y sistemas híbridos. Los sistemas conectados a la red eléctrica son los más comunes en aplicaciones urbanas e industriales, ya que permiten que la energía generada por los paneles solares se integre directamente al sistema eléctrico. Por otro lado, los sistemas aislados se utilizan principalmente en zonas donde no existe acceso a la red eléctrica, por lo que generalmente incorporan sistemas de almacenamiento energético para

garantizar el suministro continuo. Por su parte, los sistemas híbridos combinan la energía solar con otras fuentes de generación o con tecnologías de almacenamiento, con el objetivo de mejorar la confiabilidad y estabilidad del suministro energético (Karthikeyan et al., 2017; Maleki, 2018).

5.3 Sistemas de seguimiento solar

Los sistemas de seguimiento solar constituyen una estrategia tecnológica orientada a optimizar el rendimiento de los sistemas fotovoltaicos mediante el ajuste continuo de la orientación de los paneles en función de la posición del sol. Estos sistemas permiten que los módulos mantengan una orientación cercana a la perpendicular respecto a la radiación solar incidente a lo largo del día, lo que incrementa la captación de energía y, en consecuencia, la producción eléctrica. Existen principalmente dos tipos de seguidores solares: los sistemas de un eje, que permiten el movimiento del panel en una sola dirección, generalmente siguiendo el recorrido del sol de este a oeste, y los sistemas de dos ejes, que ajustan tanto la orientación horizontal como la inclinación vertical, logrando una alineación más precisa con la radiación solar. Adicionalmente, la incorporación de sensores, mecanismos de control y sistemas automatizados facilita el monitoreo y la optimización del funcionamiento de las instalaciones solares, mejorando su eficiencia operativa y el aprovechamiento del recurso solar disponible (Fedkin, 2020; Méndez-Coellar et al., 2023).

5.4 Inteligencia artificial aplicada a sistemas fotovoltaicos

Dentro del campo de la energía solar, los modelos de inteligencia artificial se utilizan principalmente para la predicción de radiación solar, la estimación de generación energética, la optimización del seguimiento solar y la detección de fallas en sistemas fotovoltaicos. Entre los algoritmos más utilizados se encuentran las redes neuronales artificiales (Artificial Neural Networks, ANN), las máquinas de vectores de soporte (Support Vector Machines, SVM), los modelos de aprendizaje automático (Machine Learning), los bosques aleatorios (Random Forest) y las técnicas de aprendizaje profundo (Deep Learning) (Mateo Romero et al., 2022).

Los modelos basados en aprendizaje automático analizan diferentes variables meteorológicas para estimar la radiación solar futura. Entre las variables más utilizadas se encuentran la temperatura ambiente, la humedad relativa, la nubosidad, la velocidad del viento y los registros históricos de irradiancia solar. La selección adecuada de estas variables resulta fundamental para mejorar la precisión de los modelos predictivos (Yajure-Ramírez & Rojas-Aranguren, 2023).

5.5 Variables climáticas y rendimiento energético

Las condiciones climáticas y operativas influyen directamente en el rendimiento energético de los sistemas fotovoltaicos, ya que variables como la radiación solar y la temperatura ambiente determinan la cantidad de energía disponible para su conversión en electricidad. Diversos estudios han señalado que estos factores afectan indicadores de desempeño como el *Performance Ratio* (PR), la eficiencia del sistema y la producción energética (Jordan & Kurtz, 2013; King et al., 2004). Asimismo, en el contexto de la inteligencia artificial aplicada a sistemas fotovoltaicos, dichas variables son utilizadas como entradas en modelos predictivos para estimar la radiación solar y optimizar el seguimiento solar, lo que incide en la precisión de métricas como el RMSE, MAE y el coeficiente de determinación (R^2) (Mateo Romero et al., 2022; Tieghi et al., 2025). De esta manera, la consideración de las condiciones ambientales resulta fundamental tanto para la evaluación del rendimiento energético como para la validación de modelos de inteligencia artificial en sistemas fotovoltaicos.

5.6 Indicadores de rendimiento energético

La evaluación del rendimiento de los sistemas fotovoltaicos es un aspecto fundamental para determinar su eficiencia y desempeño en condiciones reales de operación. Para ello, se emplean diversos indicadores técnicos que permiten analizar la relación entre la energía generada, la radiación solar disponible y las pérdidas del sistema. Entre los más utilizados se encuentran el *Performance Ratio* (PR), el rendimiento específico, el rendimiento de referencia y el factor de capacidad, los cuales permiten comparar la producción real del sistema con su potencial teórico bajo condiciones estándar. Estos indicadores constituyen la base para el análisis del desempeño energético y facilitan la identificación de ineficiencias operativas en sistemas fotovoltaicos (León-Ospina et al., 2023).

Asimismo, estos sistemas integran modelos de inteligencia artificial requiere el uso de indicadores técnicos y métricas estadísticas que permitan analizar tanto el desempeño del sistema como la precisión de los modelos predictivos. En la literatura científica, estos indicadores se agrupan en dos categorías principales: métricas de rendimiento energético del sistema fotovoltaico y métricas de evaluación de modelos de inteligencia artificial.

En cuanto a los indicadores de rendimiento energético, uno de los más utilizados es el *Performance Ratio* (PR), el cual mide la relación entre la energía generada por el sistema y la energía teóricamente disponible a partir de la radiación solar incidente, permitiendo evaluar la

calidad operativa del sistema independientemente de su tamaño o ubicación. De manera complementaria, el Factor de Capacidad (Capacity Factor) permite analizar el grado de aprovechamiento de la potencia instalada, mientras que indicadores como el Final Yield y el Reference Yield facilitan la comparación entre la producción real del sistema y su desempeño bajo condiciones estándar (Mateo Romero et al., 2022).

5.7 Métricas de evaluación de modelos de inteligencia artificial

Por otra parte, en el contexto de la inteligencia artificial aplicada a la predicción de radiación solar y optimización del seguimiento solar, se emplean diversas métricas estadísticas para evaluar la precisión de los modelos predictivos. Entre las más utilizadas se encuentran el Root Mean Square Error (RMSE), que penaliza errores grandes; el Mean Absolute Error (MAE), que mide el error promedio absoluto; el Mean Absolute Percentage Error (MAPE), que permite interpretar el error en términos porcentuales; y el coeficiente de determinación (R^2), que indica la capacidad explicativa del modelo respecto a los datos observados. Asimismo, el Mean Bias Error (MBE) es utilizado para identificar posibles sesgos en las predicciones (Tieghi et al., 2025; Yajure-Ramírez & Rojas-Aranguren, 2023).

Estas métricas permiten comparar el desempeño de diferentes algoritmos de inteligencia artificial, tales como redes neuronales, máquinas de soporte vectorial o modelos de aprendizaje profundo, facilitando la selección de aquellos que presentan mayor precisión en la estimación de variables clave como la radiación solar o la generación energética (Mateo Romero et al., 2022).

6. Diseño Metodológico

6.1 Enfoque, alcance y diseño de la investigación

La presente investigación adopta un enfoque mixto (cualitativo–cuantitativo), ya que combina el análisis interpretativo de literatura científica hallada de forma histórica y actual, con la identificación y comparación de indicadores y métricas numéricas relacionadas con el rendimiento energético de sistemas fotovoltaicos con base en el uso de la inteligencia artificial.

6.2 Búsqueda bibliográfica

La búsqueda bibliográfica se realizará en bases de datos académicas reconocidas como Scopus, Web of Science, ScienceDirect, IEEE Xplore y Google Scholar, con el propósito de identificar estudios científicos relacionados con sistemas fotovoltaicos e inteligencia artificial aplicada al seguimiento solar. Para garantizar la rigurosidad, sistematicidad y reproducibilidad del proceso

de búsqueda, se emplearán ecuaciones construidas mediante operadores booleanos, permitiendo recuperar artículos pertinentes según los objetivos de investigación. Las ecuaciones principales de búsqueda serán las siguientes:

Tabla 1 Ecuaciones de búsqueda

N°	Ecuación booleana	Bases de datos aplicables
1	("photovoltaic" OR "solar panel") AND ("artificial intelligence" OR "machine learning" OR "deep learning") AND ("performance ratio" OR "efficiency")	Scopus, Web of Science, ScienceDirect, IEEE Xplore, Google Scholar
2	("photovoltaic systems") AND ("solar tracking") AND ("artificial intelligence" OR "neural networks" OR "support vector machine")	Scopus, Web of Science, IEEE Xplore
3	("solar irradiance prediction") AND ("machine learning" OR "deep learning") AND ("RMSE" OR "MAE" OR "MAPE" OR "R ² ")	Scopus, ScienceDirect, Google Scholar
4	("photovoltaic performance") AND ("artificial intelligence") AND ("energy efficiency" OR "capacity factor" OR "final yield")	Scopus, Web of Science, ScienceDirect
5	("renewable energy") AND ("photovoltaic systems") AND ("predictive models" OR "artificial neural networks")	Scopus, Web of Science, ScienceDirect, IEEE Xplore, Google Scholar

Fuente. Elaboración propia

Adicionalmente, se podrán realizar ajustes en las ecuaciones de búsqueda según las características y filtros específicos de cada base de datos, incorporando términos relacionados con predicción de radiación solar, seguimiento solar, métricas de evaluación y desempeño energético.

6.3 Matriz de revisión bibliográfica de estudios seleccionados

La siguiente matriz de revisión bibliográfica presenta una síntesis de los principales estudios relacionados con la aplicación de inteligencia artificial en sistemas fotovoltaicos y su impacto en el rendimiento energético y el seguimiento solar. En ella se recopilan investigaciones publicadas entre 2014 y 2026, enfocadas en el uso de tecnologías como Machine Learning, Deep Learning, redes neuronales artificiales y sistemas automatizados para la predicción de radiación solar, optimización energética y evaluación del desempeño fotovoltaico.

Asimismo, la matriz permite identificar las variables analizadas con mayor frecuencia, las métricas estadísticas empleadas para validar los modelos predictivos como RMSE, MAE, MAPE y R²; los principales indicadores energéticos utilizados en la literatura científica, entre ellos el

Performance Ratio, la eficiencia y la producción energéticas. De esta manera, se facilita la comparación de enfoques metodológicos, tecnologías implementadas y hallazgos relevantes reportados por diferentes autores, contribuyendo a la construcción del marco teórico y metodológico de la presente investigación.

Tabla 2 Matriz de revisión bibliográfica de estudios seleccionados

N°	AUTOR/ AÑO	TEMA DEL ESTUDIO	MODELO IA / TECNOLOGÍA	VARIABLES ANALIZADAS	MÉTRICAS UTILIZADAS	INDICADORE S ENERGÉTICO S	HALLAZGO PRINCIPAL
1	Vargas Sierra, J. F. (2025)	Comparación entre paneles FV fijos y automatizados con seguidor solar de dos ejes	Seguimiento solar automatizado de dos ejes	Radiación solar, orientación, temperatura	Eficiencia energética (%)	Producción energética (kWh)	Los paneles automatizados con seguidor solar captan más energía que los fijos; la automatización mejora la eficiencia y el aprovechamiento energético.
2	Aguilar Sizalima, E. A. et al. (2025)	Análisis predictivo para estimación de producción energética FV en el recinto Malqui Machay mediante sistema de monitoreo	Modelos predictivos con IA	Radiación solar, generación eléctrica	RMSE, MAE	Producción energética (kWh)	La IA mejora la estimación de generación fotovoltaica con alta precisión predictiva.
3	Ospino Castro, A. et al. (2014)	Modelado y simulación de un panel fotovoltaico empleando técnicas de inteligencia artificial	Simulación matemática con IA	Temperatura, irradiancia solar	Error porcentual	Rendimiento del panel FV	El modelo representa adecuadamente el comportamiento fotovoltaico real; la simulación valida los parámetros del sistema.
4	D'Angles Woolcott, B. E. et al. (2022)	Desempeño de sistema FV de 3,25 kWp en Huancayo, Perú comparado con modelos de cálculo tradicionales	Análisis estadístico correlacional (Pearson), modelos de cálculo convencionales	Producción de energía, radiación solar histórica, condiciones climatológicas y técnicas	Coefficiente de correlación de Pearson	Producción energética (kWh)	Los ajustes propuestos a los métodos tradicionales mejoran el cálculo de producción energética, acercando los valores teóricos a los reales en condiciones andinas de alta altitud (>3200 msnm).
5	Sandoval -Ruiz, C. E. (2023)	Modelos biomiméticos para sistemas	Redes neuronales artificiales,	Condiciones ambientales regionales,	Error medio del modelo:	Eficiencia de conversión	La optimización biomimética con ANN genera

N°	AUTOR/ AÑO	TEMA DEL ESTUDIO	MODELO IA / TECNOLOGÍA	VARIABLES ANALIZADAS	MÉTRICAS UTILIZADAS	INDICADORE S ENERGÉTICO S	HALLAZGO PRINCIPAL
		de energías renovables reconfigurables basados en estructuras autosimilares	optimización biomimética, gradiente descendente, FPGA	variables de conversión energética renovable	0,0019 (3 capas)	energética renovable	modelos de alta precisión para sistemas reconfigurables; permite adaptar coeficientes a los requisitos de eficiencia y sostenibilidad de la región.
6	Fathi, M. et al. (2025)	Predicción de radiación solar y temperatura para sistema FV en techo de hotel mediante modelos híbridos LSTM, GRU y CNN	Deep Learning híbrido: CNN-GRU, LSTM, GRU, MLP	Radiación solar, temperatura, temperatura bulbo húmedo, presión superficial, humedad relativa, temperatura superficial	RMSE = 0,0368 W/m ² ; R ² = 98,54% (radiación); R ² = 97,69% (temperatura)	Producción energética (779,7 MWh/año), LPSP, emisiones CO ₂	El modelo CNN-GRU logra la mayor precisión; el sistema FV de 319 kW cubre el 62% de la demanda del hotel, reduciendo el LPSP de 1 a 0,38 y las emisiones de CO ₂ de 822,78 a 318,23 ton/año.
7	Gualdrón Guerrero, O. E. et al. (2022)	Dimensionamiento óptimo de un sistema híbrido solar-eólico con banco de baterías mediante inteligencia artificial	Redes neuronales multicapa tipo Perceptron (4-4 capas, 9 neuronas, 10 iteraciones)	Variables meteorológicas, radiación solar, velocidad del viento, distribución de Weibull	Regresión (ajuste de variables de procedimiento)	Potencial solar y eólico, relación costo/inversión/beneficio	Las redes neuronales Perceptron permiten pronosticar variables meteorológicas para optimizar el dimensionamiento de sistemas solares, eólicos y banco de baterías.
8	Ochoa-Barragán, R. et al. (2026)	Revisión de avances en IA para optimización e integración en sistemas FV y solares térmicos con análisis bibliométrico	ML y Deep Learning: predicción de irradiancia, MPPT, detección de fallas, gestión energética, mantenimiento predictivo	Irradiancia solar, variables de control de sistemas FV, parámetros de redes inteligentes	Análisis bibliométrico; métricas de evaluación de modelos (revisión general)	Eficiencia energética, MPPT, rendimiento del sistema FV	La IA evoluciona hacia marcos inteligentes auto-adaptativos; persisten retos en escasez de datos, cómputo e interpretabilidad de modelos.
9	Yajure-Ramírez, C. A. (2023)	Selección óptima de variables explicativas para modelos de pronóstico de energía en plantas FV mediante enfoque multicriterio	ML multicriterio: TOPSIS, LASSO, PCA, filtro, envoltura, incrustado	Irradiancia solar, temperatura de paneles, temperatura ambiente, velocidad del viento, energía AC	Ponderación TOPSIS: irradiancia = 1,00; T° amb = 0,204; T° panel = 0,182; viento = 0,129	Energía eléctrica AC generada	La irradiancia solar es la variable más relevante; TOPSIS permite selección óptima de variables predictoras para modelos de pronóstico FV.

N°	AUTOR/ AÑO	TEMA DEL ESTUDIO	MODELO IA / TECNOLOGÍA	VARIABLES ANALIZADAS	MÉTRICAS UTILIZADAS	INDICADORE S ENERGÉTICO S	HALLAZGO PRINCIPAL
10	Henao-Bravo, E. E. et al. (2016)	Modelo matemático de sistemas FV para búsqueda distribuida del punto de máxima potencia (MPPT)	Modelo matemático, algoritmos distribuidos de búsqueda del MPPT	Relación voltaje-corriente del módulo FV, irradiancia, pérdidas en el inductor del convertidor elevador	Error porcentual (comparación simulación vs. implementación electrónica)	Rendimiento energético, Punto de Máxima Potencia (MPPT)	El modelo matemático propuesto representa adecuadamente el comportamiento estático y dinámico del sistema FV y es validado mediante simulación electrónica tradicional.
11	Arreola Gómez, R. et al. (2015)	Diseño, construcción y evaluación de sistema de seguimiento solar para panel FV en México	Sistema de seguimiento solar autónomo (software de orientación al sol)	Radiación solar global (ISR), orientación del panel, tiempo de actualización (5, 30 y 60 min)	Rendimiento energético (%), gasto energético del seguidor (%)	Producción energética (kWh), eficiencia de captación solar	El seguimiento solar a cada 60 min genera 27,98% más energía que un panel fijo; el gasto energético del seguidor representa solo 1,3% de la ganancia total.
12	Simal Pérez et al. (2021).	Estimación de pérdidas por suciedad en planta FV experimental mediante técnicas de IA	Machine Learning (técnicas de IA)	Variables meteorológicas, corriente de cortocircuito (Isc)	nRMSE < 7%; R > 0,9; nMBE ≈ 0	Pérdidas energéticas por soiling, Performance del sistema FV	La IA estima con alta precisión las pérdidas por suciedad; incluir la corriente Isc como variable de entrada mejora la precisión del modelo.
13	Izquierdo Torres, I. F. et al. (2019)	Simulación FV con parámetros de integración en edificios — calibración y validación en Cuenca, Ecuador	Simulación en SAM (System Advisor Model), regresión lineal	Irradiancia, temperatura, inclinación y orientación del panel, condiciones de suciedad	R ² = 0,996; nRMSE = 8,16%	Eficiencia energética (%), rendimiento anual del sistema FV	La suciedad reduce la eficiencia promedio 2,77% y la temperatura hasta 30%; en latitudes ecuatoriales la orientación no afecta significativamente la producción anual.
14	Pelayo López, J. A. et al. (2018)	Comparativa de eficiencia entre sistema FV con seguimiento solar de dos ejes y sistema FV fijo	Algoritmo de búsqueda del punto máximo de energía, seguidor solar, Arduino Nano 3.0	Energía generada, orientación (eje vertical y horizontal), radiación solar, tiempo del día	Eficiencia (%), ANOVA de una vía, prueba de Tukey	Eficiencia energética: seguidor 33% vs. fijo 26,28%	El sistema con seguimiento solar logra 33% de eficiencia vs. 26,28% del fijo; en las primeras horas del día el sistema fijo genera más energía.

N°	AUTOR/ AÑO	TEMA DEL ESTUDIO	MODELO IA / TECNOLOGÍA	VARIABLES ANALIZADAS	MÉTRICAS UTILIZADAS	INDICADORE S ENERGÉTICO S	HALLAZGO PRINCIPAL
15	Vera-Dávila, A. G. et al. (2018)	Validación del modelo matemático de un panel solar con Matlab/Simulink	Modelo matemático, simulación con Matlab/Simulink (PV Array), regresión estadística	Voltaje, corriente, potencia, radiación, temperatura de operación	Error medio < 5% en todos los modelos validados experimentalmente	$R^2 = 0,9889$ (modelo matemático); $R^2 = 0,8673$ (PV Array Simulink)	Rendimiento energético del panel FV
16	Maldonado Guillén, V. A. et al. (2025)	Análisis comparativo de metodologías en sistemas de gestión energética e indicadores de desempeño energético	Análisis comparativo de modelos energéticos (metodología documental)	Factores internos (procesos operativos) y externos (regulaciones energéticas), indicadores de desempeño	Indicadores de Desempeño Energético (IDEn)	Eficiencia energética, indicadores de desempeño energético (IDEn)	Se identificaron fases estándar y prácticas óptimas para definir indicadores energéticos robustos, adaptables y alineados con necesidades estratégicas y regulatorias de las organizaciones.
17	Sandoval-Ruiz, C. E. (2020)	Arreglos FV inteligentes con modelo LFSR-Reconfigurable para optimización de conversión solar	Redes neuronales artificiales para modelado dinámico, FPGA, modelo LFSR reconfigurable	Variables eléctricas del sistema FV, reconfiguración de convertidores, control avanzado	Error porcentual (modelo fractal cuántico)	Eficiencia de conversión energética, rendimiento energético del sistema FV	El modelo LFSR con ANN permite reconfigurar inteligentemente los arreglos FV optimizando la conversión solar; se obtiene un concepto tecnológico basado en física cuántica aplicada.
18	Tacuri Chávez, B. et al. (2023)	Diseño, construcción y modelado de sistema FV inteligente (SFA) para estación de carga en Cuenca, Ecuador	Sistema FV aislado con seguimiento (SFA), modelado matemático	Radiación solar, almacenamiento energético, orientación del sistema	Eficiencia energética (%)	Eficiencia energética del sistema FV	Sistema fijo vs. doble eje: 37% de eficiencia; sistema fijo vs. móvil: 13%; el seguimiento mejora significativamente el aprovechamiento energético solar.
19	Yajure Ramírez, C. A. (2023)	Selección del modelo óptimo de predicción del Performance Ratio de planta FV mediante enfoque multicriterio con ML	K-NN, SVM, Random Forest, Regresión Logística + TOPSIS multicriterio	Performance Ratio (PR), datos de planta comercial en Chile central	Exactitud, Precisión, F1-score, Recall, ROC-AUC; TOPSIS para selección del mejor modelo	Performance Ratio (PR) — estándar IEC	La regresión logística obtuvo el mejor puntaje (100%) seguida de Random Forest (82,86%); TOPSIS permite seleccionar objetivamente el mejor clasificador para predecir el PR de plantas FV.
20	Mateo Romero,	Revisión sistemática de	ANN, Machine Learning y	Radiación solar, temperatura,	RMSE, MAE, R^2	Performance Ratio,	La IA supera enfoques clásicos

N°	AUTOR/ AÑO	TEMA DEL ESTUDIO	MODELO IA / TECNOLOGÍA	VARIABLES ANALIZADAS	MÉTRICAS UTILIZADAS	INDICADORE S ENERGÉTICO S	HALLAZGO PRINCIPAL
	H. F. et al. (2022)	aplicaciones de IA en sistemas fotovoltaicos	Deep Learning (revisión sistemática)	parámetros del módulo FV		predicción de generación energética, detección de fallas, MPPT	en predicción, MPPT y detección de fallas en sistemas FV; el alto costo computacional del entrenamiento es la principal limitación actual.
21	Mariños López, M. et al. (2022)	Rendimiento energético de sistema FV autónomo con seguidor solar en condiciones climáticas de Chachapoyas, Perú	Sistema de seguimiento solar con sensor solar (seguidor automatizado)	Irradiancia solar (>4 kWh/m ²), orientación del panel, condiciones climáticas locales	Eficiencia energética (%), gasto energético del seguidor (%)	Producción energética (kW/día), eficiencia de captación solar	El sistema con seguimiento solar genera 61,67% más energía que el panel fijo, con un gasto energético del seguidor de solo 1,5%.
22	Yajure Ramírez, C. A. (2025)	Evaluación de calidad de energía eléctrica de planta FV conectada a red mediante ML y minería de datos	Algoritmos de aprendizaje automático, minería de datos, descubrimiento de subgrupos, modelo de clasificación	THD, fluctuaciones y desbalance de voltaje, frecuencia eléctrica, factor de potencia, irradiancia solar	Exactitud de clasificación (factor de potencia: 63,56% cumplimiento), análisis de subgrupos	Calidad de energía eléctrica, factor de potencia, Performance de planta FV de 260 kWp	Casi el 100% de los parámetros cumplen estándares, excepto el factor de potencia (63,56%); la irradiancia aparece en el 40% de los subgrupos y la frecuencia en el 50%.
23	Pincay Lozada, J. et al. (2022)	Diagnóstico de fallas en módulos FV mediante redes neuronales convolucionales (CNN)	Deep Learning — CNN (Red Neuronal Convolucional)	Parámetros operativos del módulo FV, imágenes para detección de fallas	RMSE (métricas de evaluación del modelo de diagnóstico)	Eficiencia del sistema FV, detección de fallas operativas	Las técnicas de Deep Learning con CNN permiten diagnosticar fallas en el funcionamiento de módulos FV con alta precisión.
24	Amaya Jaramillo, C. D. & Pérez Toapanta, A. E. (2025)	Comparación crítica de normas MPPT en sistemas FV: EN 50530, IEC 62816 y ASTM E2848	Algoritmos MPPT, regresión múltiple (ASTM E2848), análisis comparativo normativo	Irradiancia solar (rampas 0,5–100 W/m ² s), pérdida de energía por seguimiento (εTL), potencia esperada	14 criterios de evaluación normativa, clasificación A–E (IEC 62816), nRMSE (EN 50530)	Punto de Máxima Potencia (MPPT), pérdida de energía por seguimiento, rendimiento del sistema FV	Las tres normas presentan discrepancias críticas; EN 50530 es la única que exige rampas de irradiancia específicas; la regresión múltiple de ASTM E2848 reduce precisión en condiciones dinámicas.
25	Tieghi, C. P. et al. (2025)	Revisión sistemática: aplicaciones y desafíos de la IA en la	IA para predicción solar (revisión: ANN, ML, DL)	Radiación solar, variables meteorológicas	RMSE, MAE, MBE (métricas de evaluación de modelos)	Predicción de radiación solar, eficiencia energética	La IA tiene múltiples aplicaciones para predicción solar; persisten retos en

N°	AUTOR/ AÑO	TEMA DEL ESTUDIO	MODELO IA / TECNOLOGÍA	VARIABLES ANALIZADAS	MÉTRICAS UTILIZADAS	INDICADORE S ENERGÉTICO S	HALLAZGO PRINCIPAL
		previsión de radiación solar					disponibilidad de datos, cómputo e interpretabilidad de los modelos.
26	Yajure-Ramírez, C. A., & Rojas-Aranguren, J. J. (2023)	Metodología de evaluación de desempeño de plantas FV a través de la ciencia de datos	K-Means (clustering), K-NN (clasificación)	Curvas de irradiancia, curvas de energía, indicadores de desempeño	Exactitud: energía = 91,67%; PR = 83,33%; tasa de ensuciamiento > 90%	Performance Ratio (PR), producción energética	K-Means genera clústeres significativos de potencia y PR; K-NN clasifica con alta exactitud; la tasa de ensuciamiento superior al 90% indica pérdidas importantes que requieren estudio adicional.
27	López, G. et al. (2014)	Integración de sistemas FV en campus universitario UPB como subsistema de micro red inteligente	Monitoreo en tiempo real con estaciones meteorológicas, micro red inteligente	Radiación solar, temperatura, velocidad del viento, energía generada	Eficiencia energética (producción medida en tiempo real)	Producción energética (kWh), desempeño de generadores solares	Los sistemas FV en el campus UPB permiten monitorear en tiempo real la radiación, temperatura y viento, demostrando la viabilidad de la integración FV en micro redes inteligentes universitarias.
28	Da Silva et al. (2025)	Evaluación paramétrica del modelo de un diodo en módulos FV de CdTe, CIGS, HIT y silicio monocristalino en función de variaciones de irradiancia y temperatura	Algoritmo de Evolución Diferencial Auto-Adaptativa (SADE); Modelo de un diodo — 5 parámetros: Iph, I0, n, Rs, Rsh	Irradiancia solar (G), temperatura del módulo (T); curvas I-V a distintos niveles de ambas variables	RMSE (error cuadrático medio), error relativo porcentual	Fotocorriente (Iph), corriente de saturación inversa (I0), factor de idealidad del diodo (n), resistencia serie (Rs), resistencia en paralelo (Rsh)	Los coeficientes de temperatura e irradiancia de los 5 parámetros del modelo de un diodo se extrajeron con alta precisión para cuatro tecnologías FV (CdTe, CIGS, HIT, mSi), habilitando un modelado confiable del comportamiento eléctrico real de cada tecnología
29	De Lima et al. (2017)	Análisis de desempeño de un SFCR de 2.2 kWp durante 12 meses bajo condiciones reales de operación en Brasil	Monitoreo experimental basado en norma IEC 61724; módulos silicio policristalino con inversor de red	Irradiación solar, temperatura ambiente, energía DC generada, energía AC inyectada a la red	Eficiencia del arreglo, eficiencia del sistema, eficiencia del inversor, factor de capacidad	Productividad de referencia, productividad del arreglo, productividad final, pérdidas de captura y del sistema	PR de 82.9%, superior al promedio global de sistemas similares, confirmando el alto potencial solar del noreste de Brasil para

N°	AUTOR/ AÑO	TEMA DEL ESTUDIO	MODELO IA / TECNOLOGÍA	VARIABLES ANALIZADAS	MÉTRICAS UTILIZADAS	INDICADORE S ENERGÉTICO S	HALLAZGO PRINCIPAL
						Performance Ratio	generación FV conectada a red
30	Mariños López, M. et al. (2022)	Rendimiento energético de sistema FV autónomo con seguidor solar en Chachapoyas — validación experimental	Seguidor solar automatizado con sensor solar, análisis comparativo experimental	Irradiancia solar, orientación del panel, energía generada diariamente, condiciones climáticas locales	Eficiencia energética (%), ganancia energética respecto al sistema fijo (%)	Producción energética (kW/día), eficiencia de captación solar	El sistema con seguidor solar genera significativamente más energía que el sistema fijo bajo condiciones climáticas variables de la región amazónica de Perú.
31	Gaviria, J. F. et al. (2022)	Revisión de técnicas de Machine Learning aplicadas a sistemas fotovoltaicos con énfasis en Deep Learning	ML y Deep Learning: DQL, LSTM, GRU, RL, RF, SVM, ANN, RNN (revisión sistemática de más de 100 artículos)	Irradiancia solar, generación de potencia, parámetros del sistema FV, gestión energética	RMSE, MAE (revisión general de métricas reportadas en más de 100 estudios)	Eficiencia energética, MPPT, detección de fallas y diagnóstico, predicción de generación, dimensionami ento de sistemas FV	El ML y Deep Learning superan a los métodos clásicos en control, predicción de irradiancia, detección de fallas y gestión energética en sistemas FV; se identifican oportunidades para investigación futura con código abierto.
32	Polymero poulos, I. et al. (2024)	Revisión de técnicas de monitoreo basadas en visión computacional y detección de fallas en plantas solares FV	CNN, UAV (vehículos aéreos no tripulados), ML y DL para visión computacional (revisión de 52 artículos, 2014–2024)	Datos de imagen de paneles FV, parámetros operativos, temperatura superficial, defectos visibles	Métricas de precisión de clasificación de fallas (revisión general, tendencia al alza desde introducción de CNN)	Eficiencia energética, detección de fallas, monitoreo del sistema FV, vida útil de los paneles	La introducción de CNN en la detección de fallas FV a finales de la década de 2010 generó un aumento significativo de publicaciones; los UAVs con IA permiten inspecciones seguras, escalables y rentables de plantas solares.
33	Khosravi, A. et al. (2025)	Sistema COMLAT: seguimiento solar adaptativo con ML para evaluar impacto del cambio climático en sistemas FV de uno y dos ejes	CNN-LSTM (predicción climática), XGBoost (estimación de rendimiento energético), Deep Q- Learning (control de seguimiento en tiempo real)	Radiación solar, temperatura, nubosidad, variaciones estacionales; datos de Sitapura, Jaipur, India (enero 2024–enero 2025)	RMSE = 23,5 W/m ² (predicción de irradiancia a 10 días); R ² = 0,94 (XGBoost); latencia de control sub- segundo	Producción energética (kWh), eficiencia del seguidor solar, rendimiento relativo vs. sistema fijo y de doble eje	COMLAT genera 55% más energía que instalaciones de inclinación fija y 15–20% más que seguidores de doble eje tradicionales gracias a su flexibilidad adaptativa basada en IA.

N°	AUTOR/ AÑO	TEMA DEL ESTUDIO	MODELO IA / TECNOLOGÍA	VARIABLES ANALIZADAS	MÉTRICAS UTILIZADAS	INDICADORE S ENERGÉTICO S	HALLAZGO PRINCIPAL
34	Ebied, M. A. et al. (2025)	Evaluación comprehensiva de modelos de ML para predecir la potencia máxima (MPPT) en sistemas FV independientes	LR, Ridge, Lasso, Regresión Bayesiana, Decision Tree Regression (DTR), Gradient Boosting Regression (GBR), ANN	Irradiancia solar, temperatura, tensión de circuito abierto (64,2 V), corriente de cortocircuito (5,96 A); sistema de 100 kW	RMSE = 0,006 (Im), 0,015 (Vm), 2,36 (Pm); MAE = 0,004 (Im), 0,0036 (Vm), 0,871 (Pm); R^2 = 0,99999 (DTR)	Punto de Máxima Potencia (MPPT): corriente máxima (Im), tensión máxima (Vm) y potencia máxima (Pm)	El modelo DTR supera a todos los demás algoritmos con R^2 = 0,99999; el tamaño del dataset, las condiciones operativas y el preprocesamiento de datos son los factores que más influyen en la precisión predictiva.
35	Piri, J. et al. (2025)	Predicción de energía solar mediante cinco modelos de ML: análisis comparativo de algoritmos de regresión	CatBoost, Random Forest, Gradient Boosting, XGBoost, Regresión Lineal (comparación de 5 modelos)	Temperatura, humedad, velocidad del viento, visibilidad, datos meteorológicos de estación FV	R^2 = 0,608; RMSE = 4,478 W; MAE = 3,367 W (CatBoost, entrenamient o); R^2 = 0,46; RMSE = 4,748 W; MAE = 3,583 W (validación)	Producción energética FV (W), eficiencia del sistema	CatBoost es el modelo con mejor desempeño; las variables meteorológicas como temperatura, humedad, viento y visibilidad son fundamentales para la predicción; se evidencia la necesidad de mayor regularización para reducir el sobreajuste.

Fuente: Elaboración propia a partir de la revisión bibliográfica (2026).

Respecto al enfoque cualitativo, algunos de los puntos a profundizar en el análisis serán:

- Los modelos de inteligencia artificial utilizados.
- Los enfoques metodológicos empleados en estudios previos.
- Las aplicaciones de la IA en sistemas fotovoltaicos.

Así mismo desde el enfoque cuantitativo, se profundizará en el estudio de:

- Indicadores de rendimiento energético.
- Métricas estadísticas de precisión de modelos predictivos.

En cuanto al alcance, la investigación es de tipo descriptivo, dado que busca caracterizar y sistematizar los principales indicadores, métricas y métodos de evaluación utilizados en la

literatura científica, sin manipular variables. El diseño de investigación es no experimental y documental, basándose en la revisión y análisis de fuentes secundarias (artículos científicos indexados), sin intervención directa sobre variables ni experimentación en campo.

7. Variables

Dado que se trata de una investigación de revisión bibliográfica, las variables corresponden a categorías de análisis extraídas de los estudios revisados.

7.1 Variables cualitativas

Permiten analizar los enfoques conceptuales y metodológicos:

- **Tipo de modelo de inteligencia artificial:** Redes neuronales, Machine Learning, SVM (Support Vector Machine), Deep Learning, Random Forest.
- **Aplicación del modelo:** Predicción de radiación solar, optimización del seguimiento solar, predicción energética, monitoreo.
- **Tipo de sistema fotovoltaico:** Fijo, seguimiento de un eje, seguimiento de dos ejes.
- **Método de evaluación del estudio:** Simulación, experimentación, análisis de datos históricos.
- **Variables meteorológicas utilizadas:** Radiación solar, temperatura, humedad, nubosidad, viento

7.2 Variables cuantitativas

Corresponden a indicadores y métricas utilizadas para evaluar el desempeño:

- Indicadores de rendimiento energético:
 - Performance Ratio (PR)
 - Factor de capacidad
 - Producción específica (kWh/kWp)
 - Eficiencia del sistema (%)
- Métricas de evaluación de modelos de IA:
 - Mean Squared Error (MSE)
 - Root Mean Square Error (RMSE)
 - Mean Absolute Error (MAE)
 - Mean Absolute Percentage Error (MAPE)
 - Coeficiente de determinación (R^2)

8. Población y muestra

8.1 Población

La población está conformada por artículos científicos, revisiones sistemáticas y publicaciones académicas indexadas relacionadas con sistemas fotovoltaicos, IA aplicada a energía solar, predicción de radiación y evaluación de rendimiento. Las fuentes provienen de bases de datos como Scopus, Web of Science, ScienceDirect, IEEE Xplore y Google Scholar.

8.2 Muestra

La muestra corresponde a un conjunto de 35 artículos científicos seleccionados bajo criterios de inclusión:

- Publicaciones entre 2014 y 2026.
- Estudios con indicadores de rendimiento energético.
- Investigaciones con modelos de inteligencia artificial.
- Artículos en revistas indexadas.

Tipo de muestreo: No probabilístico intencional, seleccionando estudios según su pertinencia temática (Hernández-Sampieri & Mendoza Torres, 2018).

9. Métodos e instrumentos de recolección de información

9.1 Métodos

Se emplea el método de revisión documental (búsqueda sistemática y selección de estudios) y el análisis de contenido para clasificar la información.

9.2 Instrumentos

Se utilizan matrices de revisión bibliográfica (autor, año, modelo IA, variables, métricas) y fichas de análisis para garantizar la validez del análisis.

10. Técnicas de análisis de información

La información recopilada a partir de los estudios seleccionados será procesada mediante técnicas de análisis cualitativo y cuantitativo descriptivo, con el fin de identificar patrones, tendencias y relaciones entre los diferentes enfoques reportados en la literatura científica.

Para las variables cualitativas, como el tipo de modelo de inteligencia artificial, las aplicaciones desarrolladas y los métodos de evaluación empleados, se utilizará el análisis de contenido

temático, permitiendo clasificar y comparar los enfoques metodológicos presentes en los estudios revisados.

En cuanto a las variables cuantitativas, relacionadas con indicadores de rendimiento energético y métricas estadísticas de evaluación, se aplicará estadística descriptiva, utilizando frecuencias de aparición, comparación de métricas utilizadas y análisis de rangos de valores reportados en los diferentes artículos científicos.

Finalmente, se realizará una síntesis comparativa de los estudios seleccionados, con el propósito de identificar similitudes, diferencias y tendencias en el uso de modelos de inteligencia artificial, métricas de evaluación e indicadores de desempeño energético aplicados a sistemas fotovoltaicos con seguimiento solar.

11. Consideraciones éticas

La presente investigación se desarrolla bajo principios éticos orientados al respeto de la propiedad intelectual y el uso responsable de la información científica. Debido a que el estudio corresponde a una revisión documental y no involucra intervención directa con seres humanos, animales o experimentación en campo, no representa riesgos éticos asociados a la recolección de datos personales o sensibles.

Asimismo, toda la información utilizada será obtenida de fuentes académicas confiables y debidamente citadas conforme a las normas de referenciación establecidas, garantizando el reconocimiento de los autores y evitando prácticas relacionadas con el plagio o el uso inadecuado de la información. Los documentos analizados serán utilizados exclusivamente con fines académicos e investigativos.

12. Limitaciones del estudio

La presente investigación presenta algunas limitaciones asociadas a su carácter documental y descriptivo. En primer lugar, la revisión bibliográfica se limita a artículos científicos consultados en cinco bases de datos académicas: Scopus, Web of Science, ScienceDirect, IEEE Xplore y Google Scholar, lo que puede restringir el acceso a otras publicaciones relevantes no indexadas en dichas fuentes.

Asimismo, el estudio contempla publicaciones comprendidas entre los años 2014 y 2026, con el fin de priorizar investigaciones recientes relacionadas con inteligencia artificial aplicada a sistemas fotovoltaicos; sin embargo, esta delimitación temporal podría excluir estudios pioneros o antecedentes relevantes desarrollados en periodos anteriores.

Por otra parte, el tipo de muestreo no probabilístico intencional utilizado para la selección de artículos limita la representatividad total de la literatura existente, debido a que los estudios son seleccionados según criterios de pertinencia temática y disponibilidad de información.

Finalmente, al tratarse de una investigación de enfoque documental, no se realiza validación experimental ni verificación directa de los resultados reportados en los estudios revisados, por lo que las conclusiones dependen de la calidad metodológica y confiabilidad de las fuentes analizadas.

13. Criterios de inclusión

Se seleccionarán los estudios que cumplan con las siguientes características:

- Artículos científicos publicados en revistas indexadas en bases de datos reconocidas como Scopus, Web of Science, ScienceDirect, IEEE Xplore y Google Scholar.
- Publicaciones comprendidas en el periodo entre 2014 y 2026, con el fin de incluir tanto estudios pioneros como desarrollos recientes en la aplicación de inteligencia artificial en sistemas fotovoltaicos.
- Investigaciones que aborden sistemas fotovoltaicos con integración de modelos de inteligencia artificial, especialmente en predicción de radiación solar, optimización del seguimiento solar o estimación de generación energética.
- Estudios que incluyan indicadores de rendimiento energético, tales como Performance Ratio (PR), factor de capacidad, producción específica o eficiencia del sistema.
- Investigaciones que empleen métricas estadísticas de evaluación de modelos predictivos, como Mean Squared Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE) o coeficiente de determinación (R^2).
- Artículos escritos en idioma inglés o español.
- Estudios que presenten una metodología clara, replicable y con resultados cuantificables, que permitan el análisis comparativo entre diferentes enfoques.

14. Criterios de exclusión

Se excluirán los estudios que presenten alguna de las siguientes características:


- Publicaciones anteriores a 2014, que no reflejen el desarrollo actual de la inteligencia artificial aplicada a sistemas fotovoltaicos.
- Estudios que no estén directamente relacionados con sistemas fotovoltaicos o que no incorporen inteligencia artificial en el análisis del rendimiento o seguimiento solar.
- Investigaciones que no incluyan indicadores ni métricas de evaluación, o que no permitan extraer información cuantificable relevante.
- Artículos duplicados en diferentes bases de datos.
- Documentos sin revisión por pares, como blogs, informes no científicos, presentaciones o tesis no publicadas.
- Estudios con información incompleta, sin acceso al texto completo o con deficiencias metodológicas.
- Investigaciones centradas en aplicaciones tangenciales (por ejemplo, sistemas de riego fotovoltaico o estudios climáticos generales) que no aporten directamente al análisis de métricas de rendimiento energético con inteligencia artificial.

15. Proceso de selección de estudios

- El proceso de selección de los estudios se desarrollará siguiendo una estrategia de revisión documental sistematizada basada en los lineamientos del modelo PRISMA simplificado. Inicialmente, se identificarán los artículos científicos mediante búsquedas en bases de datos académicas como Scopus, Web of Science, ScienceDirect, IEEE Xplore y Google Scholar. Posteriormente, se realizará la eliminación de registros duplicados y la revisión preliminar de títulos y resúmenes para verificar la pertinencia temática de los estudios encontrados.
- En una segunda fase, los artículos seleccionados serán evaluados mediante lectura de texto completo, aplicando los criterios de inclusión y exclusión definidos en la investigación. Finalmente, los estudios que cumplan con los criterios metodológicos y temáticos serán incorporados al análisis documental y a la matriz de revisión bibliográfica.

DIAGRAMA DE FLUJO: PROCESO DE SELECCIÓN DE ESTUDIOS (PRISMA)

n = Número de registros/estudios



Fuente: Elaboración propia basada en la metodología PRISMA

16. Técnicas de análisis de la información

La presente sección desarrolla el análisis de la información extraída de los 35 estudios que conforman la muestra definitiva de la revisión bibliográfica. En coherencia con el enfoque metodológico mixto y el alcance descriptivo declarado (Hernández-Sampieri & Mendoza Torres, 2018), el análisis se estructura en tres componentes secuenciales: análisis de contenido temático para las variables cualitativas, estadística descriptiva para las variables cuantitativas, y una síntesis comparativa integradora. El propósito es describir, medir y comparar los principales indicadores, métricas y modelos de inteligencia artificial reportados en la literatura científica sobre sistemas fotovoltaicos con seguimiento solar.

16.1 Análisis cualitativo

Las variables cualitativas se analizaron mediante el análisis de contenido temático de Braun y Clarke (2006). Las seis fases del método familiarización con los datos, generación de códigos, búsqueda de temas, revisión, definición de categorías y redacción permitieron identificar patrones en los 35 estudios sin partir de categorías previas. Dado el carácter descriptivo del trabajo, esto fue más una ventaja que una limitación.

La codificación combinó dos lógicas. Las dimensiones que los objetivos ya definían como, tipo de modelo de IA, aplicación al seguimiento solar y método de evaluación, se trataron de forma deductiva. Lo que fue apareciendo durante la revisión, como el contexto geográfico de los estudios o el tipo de sistema fotovoltaico, se codificó de forma inductiva. Cada artículo fue una unidad de análisis; los códigos quedaron en la matriz de revisión bibliográfica.

Del análisis emergieron cuatro categorías. El tipo de modelo de IA fue la más heterogénea: IA en sentido amplio (12 estudios; 27,3%), redes neuronales artificiales y Machine Learning clásico (6 cada uno; 13,6%), sistemas de seguimiento sin ML explícito (4; 9,1%) y Deep Learning (3; 6,8%). En cuanto a aplicaciones, la predicción de radiación solar y generación energética aparece en alrededor de 25 estudios, lo que la convierte en el uso dominante. Las variables meteorológicas y operativas más recurrentes son la irradiancia solar, la temperatura ambiente y la del módulo FV Yajure-Ramírez (2023) le asignó a la irradiancia la mayor ponderación TOPSIS (1,00), lo que coincide con este patrón. Los métodos de evaluación se dividen en tres: revisión sistemática de literatura, experimentación con datos reales y modelado o simulación matemática.

Los resultados se presentan con síntesis narrativa: cada categoría se sostiene con evidencia de los estudios incluidos, siguiendo el protocolo PRISMA.

16.2 Análisis cuantitativo

Las variables cuantitativas se analizaron con estadística descriptiva: frecuencias, porcentajes y comparaciones de valores entre los 35 estudios. Cada artículo se contó una sola vez, en la categoría que mejor lo representa.

El RMSE dominó como métrica de evaluación: 16 estudios, el 45,7%. Penaliza los errores grandes, y en predicción energética un error grande puede desajustar toda la planificación. Los valores reportados van de 0,006 en el modelo DTR de Ebied et al. (2025) a 23,5 W/m² en el sistema COMLAT de Khosravi et al. (2025) para predicciones a 10 días. Esa brecha no refleja diferencias de calidad entre modelos; refleja que no están haciendo lo mismo.

En rendimiento energético, la eficiencia (%) fue el indicador más usado (12 estudios; 34,3%), por delante de la producción energética (8; 22,9%) y el Performance Ratio (7; 20,0%). El PR es técnicamente el más útil para comparar instalaciones distintas no depende del tamaño del sistema ni de la irradiación disponible, pero aparece solo en uno de cada cinco estudios. Eso significa que buena parte de la literatura revisada usa indicadores que hacen difícil saber si los resultados son comparables entre sí.

16.3 Síntesis comparativa

Al cruzar los hallazgos cualitativos con los cuantitativos confirmó algunas cosas y dejó otras abiertas.

El RMSE como métrica de referencia no es solo un resultado de esta revisión: Mateo Romero et al. (2022), Gaviria et al. (2022) y Tieghi et al. (2025) llegan al mismo punto. Eso habla de cierta convergencia real en cómo el campo evalúa sus modelos. Menos convergencia hay en los modelos mismos: la coexistencia de ML clásico, Deep Learning y sistemas de seguimiento automatizado sin ML explícito confirma que el campo sigue fragmentado metodológicamente, sin un enfoque dominante claro. Por último, el Performance Ratio aparece como el indicador más útil para comparar instalaciones distintas, pero en la literatura latinoamericana revisada su uso es marginal. La mayoría de los estudios recurre a indicadores de eficiencia más generales que dificultan saber si los resultados son realmente comparables.

16.4 Identificación de categorías, variables y relaciones relevantes

Del análisis realizado se clasificaron en cuatro categorías que organizan los hallazgos de los 35 artículos revisados. La primera agrupa los tipos de modelos de inteligencia artificial utilizados; la segunda, las variables meteorológicas y operativas que los modelos toman como entrada; la tercera, las métricas estadísticas con que se evalúa su desempeño; y la cuarta, los indicadores de rendimiento energético reportados. Cada una de estas categorías se construyó a partir de los propios estudios, no de una clasificación previa, lo que permite ver tanto los patrones dominantes como las ausencias que la literatura aún no ha resuelto.

Categoría 1: Modelos de inteligencia artificial

Los estudios usaron seis tipos de modelos sin que ninguno dominara claramente. La IA en sentido amplio fue la más frecuente (8 estudios; 22,9%), seguida del Machine Learning clásico (7; 20,0%), los sistemas automatizados de seguimiento (6; 17,1%), las redes neuronales ANN y el modelado matemático (5 cada uno; 14,3%), y el Deep Learning (4; 11,4%).

Lo que sí mostró un patrón fue la precisión: los modelos de Deep Learning tendieron a los R^2 más altos. El CNN-GRU de Fathi et al. (2025) llegó a $R^2 = 98,54\%$ en predicción de radiación solar. El DTR de Ebied et al. (2025) alcanzó $R^2 = 0,99999$ en predicción de potencia máxima para sistemas de 100 kW —un valor que, en la práctica, es casi perfecto—. Esos resultados son llamativos, aunque también reflejan condiciones de aplicación muy específicas que no siempre se pueden replicar.

Categoría 2: Variables analizadas

Las tres variables más utilizadas fueron la irradiancia solar, la temperatura ambiente y la temperatura del módulo fotovoltaico. Yajure-Ramírez (2023) aplicó TOPSIS para comparar su peso predictivo y los resultados son bastante claros: la irradiancia obtuvo ponderación 1,00, mientras la temperatura ambiente quedó en 0,204, la del panel en 0,182 y la velocidad del viento en 0,129. La brecha entre la primera y las demás es grande.

Esa centralidad de la irradiancia no es solo un resultado de Yajure-Ramírez: aparece, de una forma u otra, en prácticamente todos los estudios con modelos predictivos revisados. Los modelos cambian; esa variable no desaparece.

Categoría 3: Métricas de evaluación

El RMSE apareció en 16 estudios, el 45,7% del total. Ninguna otra métrica se acercó: el error porcentual quedó en 5 estudios (14,3%), y la eficiencia directa y el MAE en 4 cada uno (11,4%). La frecuencia importa, pero más interesante es ver que la métrica elegida siguió al tipo de aplicación. Los estudios de predicción de irradiancia usaron RMSE y MAE. Los de modelado matemático reportaron error porcentual. Los trabajos multicriterio fueron los más eclécticos: mezclaron métricas estadísticas con TOPSIS, F1-score y ROC-AUC según lo que cada análisis requería. La métrica no es un detalle técnico menor; dice qué tipo de error considera relevante cada estudio.

Categoría 4: Indicadores de rendimiento energético

La eficiencia (%) fue el indicador más reportado (12 estudios; 34,3%), seguida de la producción energética (8; 22,9%) y el Performance Ratio (7; 20,0%). Lo más interesante no fue la frecuencia sino el patrón: los estudios que compararon sistemas fijos con seguidores solares mostraron mejoras consistentes en ambos indicadores, sin excepciones relevantes.

El sistema COMLAT de Khosravi et al. (2025) es el ejemplo más extremo. Integra ML para controlar el seguimiento y obtuvo un 55% más de energía que instalaciones fijas. Pero el dato que más pesa es otro: entre 15% y 20% más que seguidores de doble eje convencionales, es decir, frente a sistemas que ya hacen seguimiento. Esa diferencia no la explica el seguimiento en sí, sino la capa de inteligencia que lo controla.

De acuerdo con todo el análisis realizado previamente se obtiene además de estas cuatro categorías revela unas conexiones que no son evidentes al mirar cada una por separado.

Los modelos de Deep Learning obtuvieron los errores más bajos y los R^2 más altos de toda la revisión, pero son los menos frecuentes. Solo 4 de los 35 estudios los usaron. Esa brecha entre rendimiento y adopción sugiere que su aplicación en sistemas fotovoltaicos con seguimiento solar sigue siendo incipiente, probablemente por los requisitos de datos y capacidad computacional que implican. El Performance Ratio sigue una lógica parecida: aparece sobre todo en estudios que usan ML o ciencia de datos, pero es casi inexistente en los de seguimiento automatizado, donde los indicadores de eficiencia más generales siguen siendo la norma.

La variable que atraviesa todo es la irradiancia solar. Funciona como entrada en los modelos predictivos y como variable de control en los sistemas de seguimiento. Eso la convierte en el punto de contacto entre las dos grandes líneas de investigación que organiza esta revisión: predecir mediante IA y optimizar mediante seguimiento solar. No son líneas paralelas que corren sin tocarse; la irradiancia es donde se cruzan.

16.5 Tabulación de hallazgos

Las tablas a continuación recogen los hallazgos cuantitativos de los 35 estudios revisados. Cada artículo se contó una sola vez, en la categoría que mejor lo representa, para evitar que un mismo trabajo infle más de un indicador.

Frecuencia de métricas estadísticas de evaluación

Con el propósito de identificar las métricas estadísticas más utilizadas en la evaluación de modelos y metodologías analizadas en la literatura revisada, se realizó un análisis de los indicadores de evaluación reportados en los 35 estudios para ver cuáles predominan. La tabla recoge esa distribución: métrica, frecuencia y estudios representativos.

Tabla 3 Frecuencia de métricas estadísticas de evaluación

Métrica principal	N° de estudios	Porcentaje	Estudios representativos
RMSE (Root Mean Square Error)	16	45,7%	Fathi et al. (2025), Khosravi et al. (2025), Mateo Romero et al. (2022), Simal Pérez et al. (2021)
Error porcentual / Error medio	5	14,3%	Ospino Castro et al. (2014), Vera-Dávila et al. (2018), Da Silva et al. (2025), Henao-Bravo et al. (2016)

Eficiencia (%) como métrica directa	4	11,4%	Vargas Sierra (2025), Tacuri Chávez et al. (2023), Arreola Gómez et al. (2015), Mariños López et al. (2022)
MAE (Mean Absolute Error)	4	11,4%	Aguilar Sizalima et al. (2025), Ebied et al. (2025), Piri et al. (2025)
Otros (Pearson, ANOVA, TOPSIS, IDEn)	4	11,4%	D'Angles Woolcott et al. (2021), Pelayo López et al. (2018), Maldonado Guillén et al. (2025)
R ² (Coeficiente de determinación)	2	5,7%	Izquierdo Torres et al. (2019), Yajure Ramírez & Rojas-Aranguren (2023)
Total	35	100%	

Fuente: Elaboración propia

En la tabla evidencia una clara predominancia del RMSE (Root Mean Square Error) como principal métrica de evaluación en investigaciones relacionadas con sistemas fotovoltaicos e inteligencia artificial, al estar presente en 16 de los 35 estudios analizados (45,7%). Este comportamiento sugiere una convergencia metodológica hacia métricas capaces de penalizar errores de gran magnitud, aspecto especialmente relevante en modelos predictivos de irradiancia y generación energética, donde desviaciones elevadas pueden afectar la planificación y eficiencia operativa de los sistemas fotovoltaicos. Diversos autores coinciden en señalar que el RMSE constituye una de las métricas más robustas para evaluar modelos de predicción energética debido a su sensibilidad frente a errores extremos (Fathi et al., 2025; Khosravi et al., 2025; Mateo Romero et al., 2022). Asimismo, Simal Pérez et al. (2021) destacan que esta métrica permite comparar el desempeño de algoritmos predictivos bajo diferentes escenarios climáticos y temporales, razón por la cual su adopción es ampliamente recurrente en investigaciones basadas en Machine Learning y Deep Learning.

Por otro lado, las métricas asociadas al error porcentual o error medio representaron el 14,3% de los estudios revisados. Este grupo corresponde principalmente a investigaciones orientadas al modelado matemático convencional y análisis técnico de desempeño energético, como las desarrolladas por Ospino Castro et al. (2014), Vera-Dávila et al. (2018), Da Silva et al. (2025) y

Henao-Bravo et al. (2016). Aunque estas métricas facilitan la interpretación relativa del error y poseen una aplicación práctica sencilla, presentan limitaciones importantes frente al RMSE y MAE, debido a que tienden a reducir el impacto estadístico de errores extremos y dificultan la comparación entre sistemas fotovoltaicos con diferentes escalas de generación energética.

La eficiencia (%) apareció en 4 estudios (11,4%), principalmente en investigaciones sobre seguidores solares. Vargas Sierra (2025), Tacuri Chávez et al. (2023), Arreola Gómez et al. (2015) y Mariños López et al. (2022) la usaron para medir el incremento de rendimiento asociado al seguimiento y al control inteligente. Es un indicador intuitivo, fácil de comunicar, pero depende del contexto ambiental y de las características de cada instalación. Eso lo hace difícil de usar para comparar estudios entre sí.

El MAE llegó a la misma frecuencia (11,4%), especialmente en trabajos recientes de predicción energética. Aguilar Sizalima et al. (2025), Ebied et al. (2025) y Piri et al. (2025) lo combinaron con el RMSE porque mide el error promedio sin amplificar los valores atípicos. Los dos juntos dan una imagen más completa del desempeño del modelo que cualquiera de los dos por separado.

La categoría "Otros" agrupó herramientas como Pearson, ANOVA, TOPSIS e IDEn, también con un 11,4%. D'Angles Woolcott et al. (2021), Pelayo López et al. (2018) y Maldonado Guillén et al. (2025) las usaron para analizar correlaciones, priorizar variables y validar resultados con enfoques multicriterio. Que aparezcan en la misma revisión que estudios basados en RMSE dice algo sobre la heterogeneidad del campo: no hay un estándar compartido de evaluación.

El R^2 fue la métrica menos frecuente. Solo 2 estudios lo reportaron, el 5,7%. Izquierdo Torres et al. (2019) y Yajure Ramírez y Rojas-Aranguren (2023) obtuvieron valores altos, lo que indica modelos con buena capacidad para explicar la relación entre variables meteorológicas y producción energética. Que sea tan poco frecuente no significa que sea inferior; significa que la literatura revisada prioriza saber cuánto se equivoca el modelo sobre saber cuánto explica.

En conjunto, el RMSE y el MAE concentran la mayoría de los estudios, pero la diversidad de métricas restantes confirma lo que Gaviria et al. (2022) y Tieghi et al. (2025) ya señalaban: la falta de uniformidad en los criterios de evaluación dificulta comparar resultados entre investigaciones que, en apariencia, están respondiendo preguntas similares.

Frecuencia de indicadores de rendimiento energético

Con el fin de analizar las tendencias tecnológicas predominantes en los estudios revisados, se identificaron y clasificaron los principales modelos de inteligencia artificial y enfoques computacionales empleados en los artículos revisados. Esto permitió reconocer la frecuencia de uso de cada tipo de modelo, las metodologías con mayor aplicación en tareas de predicción, optimización y automatización. En la siguiente tabla presenta la distribución de los modelos de IA más utilizados, indicando el número de estudios, porcentaje de representación y algunos trabajos representativos.

Tabla 4 Frecuencia de indicadores de rendimiento energético

Indicador energético principal	N° de estudios	Porcentaje	Rango de valores reportados
Eficiencia energética (%)	12	34,3%	26,28% – 37% (sistemas con seguimiento); hasta 61,67% de ganancia vs. fijo
Producción energética (kWh, kW/día, MWh/año)	8	22,9%	1 – 1,65 kW/día; hasta 779,7 MWh/año (sistema 319 kW)
Performance Ratio (PR)	7	20,0%	0,50 – 0,75 según pérdidas del sistema
Rendimiento del panel / MPPT	5	14,3%	Error medio < 5% en modelos validados experimentalmente
Otros (LPSP, CO ₂ , IDEn, calidad de energía)	3	8,6%	Específicos por estudio
Total	35	100%	

Fuente: Elaboración propia

De acuerdo con la información presentada en la tabla anterior, se puede evidenciar que el la eficiencia energética (%) fue el indicador más reportado: 12 estudios, el 34,3%. Los valores oscilaron entre 26,28% y 37% en sistemas con seguimiento solar, con ganancias de hasta 61,67% frente a sistemas fijos. Vargas Sierra (2025), Tacuri Chávez et al. (2023) y Arreola Gómez et al. (2015) mostraron que el seguimiento incrementa la captación de irradiancia y mejora el rendimiento global. Es un indicador intuitivo y fácil de comunicar, pero depende del contexto ambiental y de las características de cada instalación. Eso lo hace poco útil para comparar estudios entre sí.

Asimismo, se destaca que la producción energética fue el segundo indicador con más frecuente (8 estudios; 22,9%), expresada en kWh, kW/día o MWh/año. Los valores van desde 1 kW/día en prototipos pequeños hasta 779,7 MWh/año en sistemas de 319 kW. Esa amplitud no es un defecto de la literatura; refleja que el campo abarca desde experimentos académicos hasta instalaciones de generación real. Mariños López et al. (2022) y Khosravi et al. (2025) lo consideran el indicador más directo para evaluar el impacto práctico de los algoritmos de IA bajo condiciones reales de operación.

El Performance Ratio apareció en 7 estudios (20,0%), con valores entre 0,50 y 0,75 según las pérdidas del sistema. Es el indicador más robusto para comparar instalaciones distintas porque elimina parcialmente el efecto del tamaño del sistema y de las variaciones de irradiancia. Chenlo Romero y Alonso Abella (2006) sostienen que permite evaluar el desempeño real con más precisión que la eficiencia general. Que solo lo use uno de cada cinco estudios dice bastante sobre las prioridades de la literatura revisada.

El rendimiento del panel y los sistemas MPPT estuvieron en 5 estudios (14,3%), con errores medios inferiores al 5% en validaciones experimentales. Ebied et al. (2025) y Piri et al. (2025) mostraron que los algoritmos predictivos basados en ML mejoran el seguimiento del punto de máxima potencia y reducen pérdidas operativas. Son resultados sólidos, aunque en una muestra pequeña.

Y por último en la categoría "Otros" se agruparon indicadores como LPSP, emisiones de CO₂, IDEn y parámetros de calidad de energía, presentes en 3 estudios (8,6%). Son pocos, pero señalan algo importante que algunas de las investigaciones ya evalúan los sistemas fotovoltaicos con criterios de sostenibilidad y confiabilidad, no solo de eficiencia lo que resalta ese compromiso de implementar un enfoque integral que va más allá de solo la operación de estos.

En conclusión, la eficiencia y la producción energética concentran más de la mitad de los estudios, pero la coexistencia de métricas tan distintas confirma lo que Gaviria et al. (2022) y Tieghi et al. (2025) ya señalaban: sin criterios de evaluación compartidos, comparar resultados entre investigaciones que responden preguntas similares sigue siendo difícil.

Ganancia energética de sistemas con seguimiento solar vs. sistema fijo

Con el objetivo de comparar el desempeño energético de los sistemas fotovoltaicos con seguimiento solar frente a las configuraciones fijas convencionales, diversos de los artículos

revisados analizaron el incremento en la captación y producción de energía obtenido mediante diferentes estrategias de seguimiento. Los resultados evidencian mejoras significativas en términos de eficiencia y generación energética, especialmente en sistemas automatizados y modelos inteligentes basados en inteligencia artificial. En la siguiente tabla se presentan algunos de los estudios más representativos de la revisión realizada, indicando el tipo de seguimiento implementado, la ganancia obtenida respecto al sistema fijo y la métrica utilizada para evaluar el desempeño.

Tabla 5 Ganancia energética de sistemas con seguimiento solar vs. sistema fijo

Estudio	Tipo de seguimiento	Ganancia vs. sistema fijo	Métrica reportada
Arreola Gómez et al. (2015)	Un eje — actualización cada 60 min	+27,98%	Producción energética (kWh)
Pelayo López et al. (2018)	Dos ejes — sensor continuo	+6,72 pp (33% vs. 26,28%)	Eficiencia (%)
Mariños López et al. (2022)	Un eje — sensor solar	+61,67%	Producción energética (kW/día)
Vargas Sierra (2025)	Dos ejes — automatizado	Mayor captación solar	Eficiencia energética (%)
Tacuri Chávez et al. (2023)	Doble eje vs. fijo	+24 pp (37% vs. 13%)	Eficiencia (%)
Khosravi et al. (2025) — COMLAT	ML adaptativo (CNN-LSTM + DQL)	+55% vs. fijo; +15–20% vs. doble eje convencional	Producción energética (kWh)

Fuente: Elaboración propia

De acuerdo con esta información se puede analizar que estos artículos brindar información sobre los sistemas con seguimiento solar superan a las instalaciones fijas en todos los estudios revisados, sin importar la tecnología. Tanto los seguidores de un eje como los de doble eje incrementan la captación de irradiancia y la producción energética, aunque las mejoras más altas se concentran en sistemas que incorporan IA y algoritmos adaptativos.

Asimismo, en seguimiento de un eje, las ganancias son significativas incluso con configuraciones simples. Arreola Gómez et al. (2015) documentaron un 27,98% más de producción respecto a sistemas fijos con un mecanismo de actualización cada 60 minutos. Mariños López et al. (2022) llegaron al 61,67% usando un seguidor de un eje con sensor solar. La diferencia entre ambos resultados sugiere que el tipo de sensor y la frecuencia de actualización pesan tanto como el seguimiento en sí. En doble eje, las mejoras se concentran en eficiencia más que en producción. Pelayo López et al. (2018) midieron una ganancia de 6,72 puntos porcentuales (de 26,28% a

33%) con seguimiento continuo por sensores. Tacuri Chávez et al. (2023) reportaron una diferencia mayor: 24 puntos porcentuales, pasando del 13% al 37% al cambiar de fijo a doble eje. La razón técnica es conocida: el doble eje mantiene mejor la perpendicularidad al sol durante el día y reduce las pérdidas por cambios de posición.

Por otro lado, Vargas Sierra (2025) aporta una observación complementaria: los sistemas automatizados de doble eje captan más energía que las configuraciones convencionales, aunque no cuantifica la ganancia. Lo que sí confirma es que la automatización mejora la estabilidad operativa, no solo el pico de captación.

El caso que más resalta es el sistema COMLAT de Khosravi et al. (2025). Combina Deep Learning (CNN-LSTM) con aprendizaje por refuerzo profundo (Deep Q-Learning) y reportó un 55% más de producción que sistemas fijos. Pero el dato que realmente destaca es que entre un 15% y 20% más que seguidores convencionales de doble eje. Esa diferencia frente a sistemas que ya hacen seguimiento no la explica el seguimiento; la explica la capa de inteligencia que decide cómo y cuándo ajustar la posición en función de las variaciones meteorológicas en tiempo real.

En general todos destacan lo que a mayor innovación tecnológica se generan mayores ganancias. Los seguidores de un eje mejoran la generación de energía, los de doble eje afinan la captación, y los sistemas con IA hacen lo que los sistemas tradicionales no pueden, anticipar. Mateo Romero et al. (2022) y Gaviria et al. (2022) ya advertían que la integración de IA en sistemas fotovoltaicos abre la puerta a estrategias de control predictivo y adaptación dinámica, y los resultados de esta revisión confirman que esa transición ya está en marcha.

Valores de R^2 y RMSE por modelo de IA

Con el propósito de evaluar la precisión y confiabilidad de los modelos de inteligencia artificial aplicados a sistemas fotovoltaicos, diversos estudios reportaron métricas estadísticas como el coeficiente de determinación (R^2) y el error cuadrático medio (RMSE). Estos indicadores permiten comparar el desempeño predictivo de los diferentes algoritmos en variables relacionadas con la generación energética, irradiancia, temperatura y optimización del punto de máxima potencia. En la siguiente tabla se presentan algunos de los modelos más representativos, junto con las métricas obtenidas y las variables predichas en cada investigación.

Tabla 6 Valores de R^2 y RMSE por modelo de IA

Estudio	Modelo de IA	R^2	RMSE	Variable predicha
Ebied et al. (2025)	Decision Tree Regression (DTR)	0,99999	0,006 (Im); 2,36 (Pm)	Corriente y potencia máxima (MPPT)
Fathi et al. (2025)	CNN-GRU híbrido	98,54%	0,0368 W/m ²	Radiación solar
Fathi et al. (2025)	CNN-GRU híbrido	97,69%	0,0445 °C	Temperatura
Izquierdo Torres et al. (2019)	Regresión lineal (SAM)	0,996	8,16% (nRMSE)	Producción energética anual
Khosravi et al. (2025)	XGBoost	0,94	23,5 W/m ²	Irradiancia solar (10 días)
Piri et al. (2025)	CatBoost	0,608	4,478 W	Energía solar (W)
Simal Pérez et al. (2021)	Machine Learning (IA)	$R > 0,9$	nRMSE < 7%	Pérdidas por suciedad

Fuente: Elaboración propia

Los modelos de IA aplicados a sistemas fotovoltaicos alcanzaron niveles de precisión predictiva altos, sobre todo los basados en Machine Learning y Deep Learning. El resultado más extremo es el del Decision Tree Regression (DTR) de Ebied et al. (2025) que es de $R^2 = 0,99999$ y valores de RMSE muy bajos para la predicción de corriente y potencia máxima en el sistema MPPT. Fathi et al. (2025) llegaron a cifras comparables con un modelo híbrido CNN-GRU: $R^2 = 98,54\%$ para radiación solar y $97,69\%$ para temperatura, con RMSE inferiores a 0,05. Lo interesante de los modelos de Deep Learning no es solo el ajuste, sino que pueden capturar las relaciones no lineales entre variables meteorológicas que los métodos tradicionales tienden a perder.

Asimismo, XGBoost y CatBoost mostraron resultados más moderados, pero igualmente significativos. Khosravi et al. (2025) alcanzaron $R^2 = 0,94$ en predicción de irradiancia a 10 días; Piri et al. (2025) obtuvieron $R^2 = 0,608$ en predicción de energía solar. La brecha entre ambos no es necesariamente una diferencia de calidad, muestra el horizonte temporal y la calidad de los datos de entrada pesan tanto como el algoritmo elegido. Izquierdo Torres et al. (2019) recuerdan que los métodos clásicos siguen siendo útiles. Su regresión lineal alcanzó $R^2 = 0,996$, un valor

competitivo con los modelos más sofisticados. Sus errores fueron mayores, sí, pero la lección es que no siempre hace falta una red neuronal para obtener un ajuste sólido.

Los modelos de Deep Learning y ML avanzado lideran en precisión, pero la elección del modelo depende menos del estado del arte y más del tipo de variable que se quiere predecir y de los datos disponibles. Mateo Romero et al. (2022) y Gaviria et al. (2022) ya señalaban que la IA está reconfigurando la predicción y la optimización en sistemas fotovoltaicos, aunque los resultados de esta revisión sugieren que la transición es desigual los mejores algoritmos están disponibles, pero no todos los estudios pueden permitirse las condiciones que los hacen funcionar.

Distribución geográfica de los estudios

Con el fin de identificar de que ubicación geográfica proceden las investigaciones analizadas, se realizó una clasificación de los estudios según la región o país donde fueron desarrollados. Este análisis permitió evidenciar las zonas con mayor producción científica relacionada con la aplicación de inteligencia artificial y sistemas fotovoltaicos, así como reconocer el contexto regional que predomina en los artículos revisados. La siguiente tabla presenta la distribución geográfica de los estudios seleccionados, donde muestra el número de investigaciones y su porcentaje de representación.

Tabla 7 Distribución geográfica de los estudios

Región / País	N° de estudios	Porcentaje
América Latina (Colombia, Ecuador, Perú, México, Venezuela, Chile)	18	51,4%
Internacional / Sin localización específica (revisiones sistemáticas)	7	20,0%
Europa (España, Grecia)	5	14,3%
Asia y Medio Oriente (India, Tailandia)	3	8,6%
Norte América (EE. UU., Canadá)	2	5,7%
Total	35	100%

Fuente: Elaboración propia

Los resultados evidencian una concentración significativa de la producción científica en América Latina, lo cual puede interpretarse desde dos perspectivas principales. En primer lugar, esta tendencia podría reflejar un creciente interés regional por el tema estudiado, impulsado por necesidades contextuales específicas, mayor accesibilidad a bases de datos regionales o fortalecimiento de redes académicas latinoamericanas. Este hallazgo es consistente con la tendencia observada en los últimos años de aumento en la producción científica en países emergentes.

Sin embargo, esta concentración también puede sugerir un posible sesgo de localización en la estrategia de búsqueda o en los criterios de inclusión de estudios, lo que limitaría la representatividad global de los resultados. La menor participación de regiones como Norteamérica, Europa y Asia podría indicar que existen barreras de idioma, acceso a bases de datos o diferencias en las líneas de investigación predominantes en cada región.

Por otro lado, la presencia de un 20% de estudios internacionales o sin localización específica aporta un elemento de equilibrio, ya que permite incorporar evidencia más global y reduce parcialmente la dependencia de contextos regionales específicos. No obstante, su proporción sigue siendo inferior a la producción latinoamericana.

Distribución temporal de los estudios

Para analizar la evolución temporal de las investigaciones relacionadas con inteligencia artificial y sistemas fotovoltaicos, los artículos seleccionados fueron organizados según su período de publicación. Esta distribución permitió identificar las etapas de desarrollo tecnológico predominantes, desde los primeros trabajos centrados en modelado y simulación hasta la consolidación reciente de modelos híbridos, aprendizaje profundo y enfoques multicriterio, a continuación, se presenta la distribución temporal de los estudios revisados, indicando el número de investigaciones, su porcentaje de representación y las principales características observadas en cada período.

Tabla 8 Distribución temporal de los estudios

Período	N° de estudios	Porcentaje	Observación
2014–2015	3	8,6%	Primeros estudios: modelado FV, seguimiento solar y micro redes en América Latina

2016–2019	5	14,3%	Incorporación de ML clásico, validación experimental y análisis de desempeño de sistemas FV
2020–2022	9	25,7%	Expansión de Deep Learning y ciencia de datos aplicada a FV
2023–2026	18	51,4%	Consolidación de modelos híbridos y enfoques multicriterio
Total	35	100%	

Fuente: Elaboración propia

La revisión realizada de los artículos permite evidenciar cómo estos van evolucionando y volviéndose más complejos en los conceptos a lo largo del tiempo. Entre 2014 y 2015, tres de los 35 artículos analizados (8,6%) corresponden a los primeros estudios sobre modelado FV, seguimiento solar y micro redes en América Latina. Son trabajos centrados en demostrar la teoría y validar los modelos, con menor énfasis en la implementación práctica.

Entre 2016 y 2019 aparecen 5 estudios (14,3%), con Machine Learning clásico aplicado a la predicción de irradiancia y validación experimental de sistemas FV. El volumen es modesto, pero con un cambio en el enfoque: se comienza a hablar de la integración real de IA en el análisis energético fotovoltaico. En 2020 y 2022 se concentran 9 de los 35 artículos seleccionados (25,7%), con Deep Learning y ciencia de datos como enfoques dominantes. Y entre 2023 y 2026, los 18 estudios restantes (51,4%): modelos híbridos, enfoques multicriterio y optimización avanzada. Más de la mitad de los artículos que pasaron los criterios de inclusión se publicaron en los últimos tres años. Esto muestra cómo se van aplicando nuevas técnicas a través de los años que optimizan, innovan y aprovechan mejor el recurso solar y las nuevas tecnologías disponibles.

17. Conclusiones

Los resultados evidencian una clara tendencia hacia el uso de métricas basadas en error, principalmente RMSE y MAE, como criterios predominantes para la evaluación de modelos de inteligencia artificial aplicados a sistemas fotovoltaicos. Sin embargo, la falta de estandarización en los indicadores de desempeño limita la comparabilidad entre estudios y dificulta la consolidación de marcos metodológicos unificados.

Se identificó que los modelos de Machine Learning y Deep Learning presentan los mejores niveles de desempeño predictivo, alcanzando valores elevados de R^2 y bajos errores en variables

como irradiancia, temperatura y potencia energética. No obstante, su adopción aún es desigual, predominando el uso de enfoques híbridos y modelos de Machine Learning clásico frente a arquitecturas más complejas como Deep Learning.

La evolución temporal y geográfica de la literatura muestra una consolidación reciente del campo, con un crecimiento significativo a partir de 2020 y una mayor concentración de estudios en América Latina. Esto evidencia un proceso de maduración de la investigación en energías fotovoltaicas inteligentes, caracterizado por la transición desde modelos de simulación tradicionales hacia enfoques avanzados basados en inteligencia artificial y optimización energética.

Referencias

- Aguilar Sizalima, E. A., Vásquez Carrera, P. J., & Hidalgo Osorio, W. A. (2025). Análisis predictivo para la estimación de producción energética fotovoltaica en el recinto Malqui Machay mediante un sistema de monitoreo de generación eléctrica solar. *INSTA Magazine*, 8(1), 20–35. <https://doi.org/10.63074/26973308.v8i1.72>
- Ahmed, R., Sreeram, V., Mishra, Y., & Arif, M. D. (2020). A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization. *Renewable and Sustainable Energy Reviews*, 124, 109792. <https://doi.org/10.1016/j.rser.2020.109792>
- Amaya Jaramillo, C. D., & Pérez Toapanta, A. E. (2025). Comparación crítica de normas MPPT en sistemas fotovoltaicos: EN 50530, IEC 62816 y ASTM E2848. *Boletín Científico Ideas y Voces*, 5(3), 233–250. <https://doi.org/10.60100/bciv.v5i3.251>
- Arreola Gómez, R., Quevedo Nolasco, A., Castro Popoca, M., Bravo Vinaja, Á., & Reyes Muñoz, D. (2015). Diseño, construcción y evaluación de un sistema de seguimiento solar para un panel fotovoltaico. *Revista Mexicana de Ciencias Agrícolas*, 6(8), 1715–1727. <https://doi.org/10.29312/remexca.v6i8.490>
- Ayala Villacis, V. F. (2018). Modelamiento de un sistema fotovoltaico de alta eficiencia y análisis de producción energética bajo diferentes condiciones climáticas estacionarias [Tesis de pregrado, Universidad Politécnica Salesiana]. Repositorio Institucional UPS. <https://dspace.ups.edu.ec/handle/123456789/15088>
- Bamisile, O., Cai, D., Oluwasanmi, A., Ejiyi, C., Ukwuoma, C. C., Ojo, O., Mukhtar, M., & Huang, Q. (2022). Comprehensive assessment, review, and comparison of AI models for solar irradiance prediction based on different time/estimation intervals. *Scientific Reports*, 12, 9644. <https://doi.org/10.1038/s41598-022-13652-w>
- Barhmi, K., Heynen, C., Golroodbari, S., & van Sark, W. (2024). A review of solar forecasting techniques and the role of artificial intelligence. *Solar*, 4(1), 99–135. <https://doi.org/10.3390/solar4010005>
- da Silva, A. J., Oliveira, A. F., & Rubinger, R. M. (2025). Parametric evaluation of CdTe, CIGS, HIT, and mSi solar modules as a function of temperature and irradiance variation.

Journal of Renewable and Sustainable Energy, 17(5), 053503.

<https://doi.org/10.1063/5.0289606>

D'Angles Woolcott, B. E., Cueva Ríos, P. H., & Orellana Mendoza, W. T. (2021). Estudio del desempeño del sistema fotovoltaico de 3.25 kWp de la UNCP en la ciudad de Huancayo – Perú y su comparación con modelos de cálculo tradicionales. *Prospectiva Universitaria en Ingeniería y Tecnología*, 18(1), 65–76.

<https://doi.org/10.26490/uncp.prospectivauniversitaria.2021.18.1651>

de Lima, L. C., de Araújo Ferreira, L., & de Lima Morais, F. H. B. (2017). Performance analysis of a grid connected photovoltaic system in northeastern Brazil. *Energy for Sustainable Development*, 37, 79–85. <https://doi.org/10.1016/j.esd.2016.11.003>

Duarte, L. F., Revollo, J., Betancur, D., Restrepo, C. E., López, G. J., & Isaac, I. A. (2022, October). Analysis of performance of photovoltaic systems based on solar irradiation at UPB ecocampus Medellín. In 2022 IEEE PES Generation, Transmission and Distribution Conference and Exposition–Latin America (IEEE PES GTD Latin America) (pp. 1-7). IEEE. [10.1109/IEEEPESGTDLatinAmeri53482.2022.10038292](https://doi.org/10.1109/IEEEPESGTDLatinAmeri53482.2022.10038292)

Ebied, M. A., Hamad, S. A., Ghalib, M. A., Munshi, A., & Alotaibi, M. (2025). Evaluating machine learning models comprehensively for predicting maximum power from photovoltaic systems. *Scientific Reports*, 15, 10750. <https://doi.org/10.1038/s41598-025-91044-6>

Fathi, M., Allahyari, S., Ahmadi, A., Zahedi, A., & Asiaei, S. (2025). Enhanced global solar irradiance and temperature forecasting for rooftop PV power generation prediction using multi-step LSTM and GRU based hybrid models. *Energy Conversion and Management: X*, 28, 101351. <https://doi.org/10.1016/j.ecmx.2025.101351>

Fedkin, M. (2020). *Types of solar tracking systems*. EME 812: Utility Solar Power and Concentration, The Pennsylvania State University. <https://www.e-education.psu.edu/eme812/node/584>

Gaviria, J. F., Narváez, G., Guillen, C., Giraldo, L. F., & Bressan, M. (2022). Machine learning in photovoltaic systems: A review. *Renewable Energy*, 196, 298–318. <https://doi.org/10.1016/j.renene.2022.06.105>

- Gualdrón Guerrero, O. E., Laguado Ramírez, R. I., & Flórez Serrano, E. G. (2022). *Dimensionamiento óptimo de un sistema híbrido de energía solar-eólica y banco de baterías utilizando inteligencia artificial*. *Revista Colombiana de Tecnologías de Avanzada (RCTA)*, 2(40). <https://doi.org/10.24054/rcta.v2i40.2363>
- Henao-Bravo, E. E., Márquez-Viloria, D. A., Villegas-Ceballos, J. P., Serna-Garcés, S. I., Ramos-Paja, C. A., & González-Montoya, D. (2016). *Modelo matemático de sistemas fotovoltaicos para búsqueda distribuida del punto de máxima potencia*. *TecnoLógicas*, 19(37), 107–124. <https://doi.org/10.22430/22565337.88>
- Hernández-Sampieri, R., & Mendoza Torres, C. P. (2018). *Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Education. <https://artes.upn.edu.co/wp-content/uploads/2024/11/METODOLOGIA-DE-LA-INVESTIGACION-Sampieri-Mendoza-2018.pdf>
- Izquierdo-Torres, I. F., Pacheco-Portilla, M. G., González-Morales, L. G., & Zalamea-León, E. F. (2019). Simulación fotovoltaica considerando parámetros de integración en edificaciones. *Ingenius. Revista de Ciencia y Tecnología*, (21), 21–31. <https://doi.org/10.17163/ings.n21.2019.02>
- Jordan, D. C., & Kurtz, S. R. (2013). Performance ratio revisited and temperature coefficient for energy rating. *Solar Energy*, 86(6), 1497–1505. <https://doi.org/10.1016/j.solener.2012.06.010>
- Karthikeyan, V., Rajasekar, S., Das, V., Karuppanan, P., & Singh, A. K. (2017). *Grid-connected and off-grid solar photovoltaic system*. En F. M. R. Islam, K. Al Mamun, & M. T. O. Amanullah (Eds.), *Smart Energy Grid Design for Island Countries: Challenges and Opportunities* (pp. 125–157). Springer. https://doi.org/10.1007/978-3-319-50197-0_5
- Khosravi, A., Sharma, R., Khosravi, R., Singh, R., & Panchal, H. (2025). A machine learning approach to assess the climate change impacts on single and dual-axis tracking photovoltaic systems. *Scientific Reports*, 15, 10831. <https://doi.org/10.1038/s41598-025-10831-3>
- King, D. L., Boyson, W. E., & Kratochvil, J. A. (2004). *Photovoltaic array performance model* (SAND2004-3535). Sandia National Laboratories. <https://doi.org/10.2172/919131>

- León-Ospina, C., Arias-Zarate, H., & Hernandez, C. (2023). Performance Evaluation of Photovoltaic Projects in Latin America. *International Journal of Advanced Computer Science and Applications*, 14(1), 201–212.
<https://dx.doi.org/10.14569/IJACSA.2023.0140123>
- López, G. J., Isaac, I. A., González, J. W., & Cardona, H. A. (2014). *Integración de energías renovables (solar fotovoltaica) en campus UPB Laureles-micro red inteligente. Investigaciones Aplicadas*, 8(2), 152–159. <http://hdl.handle.net/20.500.11912/6817>
- Maldonado Guillén, V. A., Pérez-Rodríguez, J. A., & Rodríguez-Borges, C. G. (2025). Análisis de metodologías empleadas en los sistemas de gestión energética y sus indicadores. *Revista Científica FINIBUS – Ingeniería, Industria y Arquitectura*, 8(15), 103–111.
<https://doi.org/10.56124/finibus.v8i15.011>
- Maleki, A. (2018). Modeling and optimum design of an off-grid PV/WT/FC/diesel hybrid system considering different fuel prices. *International Journal of Low-Carbon Technologies*, 13(2), 140–147. <https://doi.org/10.1093/ijlct/cty006>
- Mamodiya, U., Kishor, I., Garine, R., Ganguly, P., & Naik, N. (2025). Artificial intelligence-based hybrid solar energy systems with smart materials and adaptive photovoltaics for sustainable power generation. *Scientific Reports*, 15, 17370.
<https://www.nature.com/articles/s41598-025-01788-4>
- Mariños López, M., Oliva-Cruz, M., Gosgot Angeles, W., & Espinoza Canaza, F. I. (2022). Rendimiento energético de un sistema fotovoltaico autónomo con seguidor solar bajo las condiciones climáticas de Chachapoyas. *Revista de Investigación de Agroproducción Sustentable*, 6(1), 83–90. <https://doi.org/10.25127/aps.20221.858>
- Mateo Romero, H. F., González Rebollo, M. A., Cardeñoso-Payo, V., Alonso Gómez, V., Redondo Plaza, A., Moyo, R. T., & Hernández-Callejo, L. (2022). Applications of artificial intelligence to photovoltaic systems: A review. *Applied Sciences*, 12(19), 10056.
<https://doi.org/10.3390/app121910056>
- Méndez-Coellar, C. A., Dután-Rojas, A. R., & Moscoso-Bernal, S. A. (2023). Control para la operación de una estación de carga inteligente fotovoltaica. *MQRInvestigar*, 7(3), 2579–2602. <https://doi.org/10.56048/MQR20225.7.3.2023.2579-2602>

- Ochoa-Barragán, R., Saavedra-Sánchez, L. D., Nápoles-Rivera, F., Ramírez-Márquez, C., Lira-Barragán, L. F., & Ponce-Ortega, J. M. (2026). Artificial intelligence enabling intelligent solar energy systems: Integration and emerging directions. *Processes*, 14(7), 1167. <https://doi.org/10.3390/pr14071167>
- Ospino Castro, A., Robles Algarín, C., & Duran Pabón, A. (2014). Modelado y simulación de un panel fotovoltaico empleando técnicas de inteligencia artificial. *Energética*, 35(3), 225–233. http://scielo.sld.cu/scielo.php?pid=S1815-59012014000300007&script=sci_arttext
- Pa, M., & Kazemi, A. (2022). A fault detection scheme utilizing convolutional neural network for PV solar panels with high accuracy. <https://arxiv.org/abs/2210.09226>
- Pelayo López, J. A., Luna Soto, A., Bernabe Ramos, F., & Guzmán Flores, B. (2018). Comparativa de la eficiencia entre un sistema fotovoltaico con seguimiento solar y un sistema fotovoltaico fijo. *CIBA Revista Iberoamericana de las Ciencias Biológicas y Agropecuarias*, 7(13). <https://doi.org/10.23913/ciba.v7i13.76>
- Pincay Lozada, J., Mulcú Nieto, L. F., & López Sotelo, J. A. (2022). Red neuronal convolucional para el diagnóstico de módulos fotovoltaicos. En *Encuentro Internacional de Educación en Ingeniería ACOFI 2022*. Asociación Colombiana de Facultades de Ingeniería (ACOFI). <https://doi.org/10.26507/paper.2563>
- Piri, J., et al. (2025). Solar energy prediction through machine learning models: A comparative analysis of regressor algorithms. *PLOS ONE*, 20(1), e0315955. <https://doi.org/10.1371/journal.pone.0315955>
- Polymeropoulos, I., Bezyrgiannidis, S., Vrochidou, E., & Papakostas, G. A. (2024). Enhancing solar plant efficiency: A review of vision-based monitoring and fault detection techniques. *Technologies*, 12(10), 175. <https://doi.org/10.3390/technologies12100175>
- Salazar-Peña, N., Tabares, A., & González-Mancera, A. (2024). AI-powered dynamic fault detection and performance assessment in photovoltaic systems. <https://arxiv.org/abs/2409.00052>

- Sandoval-Ruiz, C. E. (2020). Arreglos fotovoltaicos inteligentes con modelo LFSR-reconfigurable. *Ingeniería. Revista de la Universidad de Costa Rica*, 30(2), 32–61. <https://doi.org/10.15517/ri.v30i2.39484>
- Sandoval-Ruiz, C. E. (2023). Biomimética aplicada a modelos de sistemas de energías renovables reconfigurables basados en estructuras autosimilares. *Revista Técnica de la Facultad de Ingeniería, Universidad del Zulia*, 46, e234602. <https://doi.org/10.22209/rt.v46a02>
- Simal Pérez, N., Alonso-Montesinos, J., & Batlles, F. J. (2021). Estimation of soiling losses from an experimental photovoltaic plant using artificial intelligence techniques. *Applied Sciences*, 11(4), 1516. <https://doi.org/10.3390/app11041516>
- Tacuri Chávez, B., Peralta Guanoquiza, J., Rivas Villa, M., & Moscoso Bernal, S. (2023). Diseño, construcción y modelado de un sistema fotovoltaico inteligente (SFA) para una estación de carga. *Killkana Técnica*, 7(2). <https://doi.org/10.26871/killkanatecnica.v7i2.1075>
- Tieghi, C. P., de Lima Caneppele, F., Dal Pai, A., Godinho, E. Z., Almeida, C. F. M., Malagueta, D. C., & Frigo, M. M. (2025). Aplicações e desafios da inteligência artificial na previsão da radiação solar: uma revisão sistemática. *Revista Brasileira de Climatologia*, 36(21), 170–201. <https://doi.org/10.55761/abclima.v36i21.18872>
- Vargas Sierra, J. F. (2025). Análisis comparativo de generación energía fotovoltaica entre paneles solares fijos versus paneles automatizados. *Ciencia Latina Revista Científica Multidisciplinar*, 8(6), 9242–9257. https://doi.org/10.37811/cl_rcm.v8i6.15602
- Vera-Dávila, A. G., Delgado-Ariza, J. C., & Sepúlveda-Mora, S. B. (2018). Validación del modelo matemático de un panel solar empleando la herramienta Simulink de Matlab. *Revista de Investigación, Desarrollo e Innovación*, 8(2), 343–356. <https://doi.org/10.19053/20278306.v8.n2.2018.7972>
- Yajure Ramírez, C. A. (2023). Selección del modelo óptimo de predicción de la relación de desempeño de una planta solar fotovoltaica. Un enfoque multicriterio basado en algoritmos de aprendizaje automático. *Ciencia, Ingenierías y Aplicaciones*, 6(2), 7–29. <https://doi.org/10.22206/cyap.2023.v6i2.2935>

Yajure Ramírez, C. A. (2025). Evaluación de la calidad de la energía eléctrica suministrada por una planta solar fotovoltaica conectada a la red haciendo uso de algoritmos de aprendizaje automático y de minería de datos. *Ingeniería y Desarrollo*, 43(1), 44–63. <https://doi.org/10.14482/inde.43.01.489.326>

Yajure-Ramírez, C. A. (2023). Enfoque multicriterio para la selección óptima de variables explicativas para modelos de pronóstico de energía eléctrica de plantas solares fotovoltaicas. *Revista Tecnológica ESPOL*, 35(3). <https://doi.org/10.37815/rte.v35n3.1045>

Yajure-Ramírez, C. A., & Rojas-Aranguren, J. J. (2023). *Metodología para la evaluación de desempeño de plantas solares fotovoltaicas a través del uso de la ciencia de datos*. *Revista Tecnológica ESPOL*, 35(1), 120–136. <https://doi.org/10.37815/rte.v35n1.1011>