



COLEGIO DE INGENIEROS DEL PERÚ



INTELIGENCIA ARTIFICIAL Y ENERGÍAS RENOVABLES

Un futuro energético inteligente y sostenible

SAUL HUAQUIPACO
NORMAN BELTRÁN
JOSÉ CRUZ



ARCHIVO SOLO PARA VISUALIZACIÓN DIGITAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL



COLEGIO DE INGENIEROS DEL PERÚ

INTELIGENCIA ARTIFICIAL **y**

ENERGÍAS RENOVABLES

Un futuro energético inteligente y sostenible

SAUL HUAQUIPACO ENCINAS

NORMAN JESÚS BELTRÁN CASTAÑÓN

JOSÉ EMMANUEL CRUZ DE LA CRUZ

LIMA / PERÚ
2024

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL



COLECCIÓN BICENTENARIO DEL PERÚ



COLEGIO DE INGENIEROS DEL PERÚ

INTELIGENCIA ARTIFICIAL Y ENERGÍAS RENOVABLES

Un futuro energético inteligente y sostenible

- © Saul Huaquipaco Encinas
- © Norman Jesús Beltrán Castañón
- © José Emmanuel Cruz de la Cruz

Primera edición digital: diciembre 2024

Editado por:

© Colegio de Ingenieros del Perú - Consejo Nacional
Av. Arequipa 4947, Miraflores
www.cip.org.pe | Telf. 445-6540 / 446-6997

Derechos Reservados

Hecho el Depósito Legal en la Biblioteca Nacional del Perú N° 2024-13452

ISBN: 978-612-49780-4-3

El Colegio de Ingenieros del Perú no se verá afectado por el contenido de la obra. En consecuencia, los autores son responsable ante cualquier controversia o conflicto de interés.

Prohibida la reproducción de este libro por cualquier medio, total o parcialmente, sin permiso expreso de los editores y/o autores.

Publicado en el Perú



COLEGIO DE INGENIEROS DEL PERÚ

Directiva Nacional del Colegio de Ingenieros del Perú

2022-2024

Ing. María del Carmen Ponce Mejía
DECANA NACIONAL

Ing. Segundo Eduardo Reusche Castillo
VICEDECANO NACIONAL

Ing. Marco Antonio Cabrera Huamán
DIRECTOR SECRETARIO NACIONAL

Ing. Jaime Antonio Ruiz Béjar
DIRECTOR TESORERO NACIONAL

Ing. Jesús García Melgarejo
DIRECTOR PROSECRETARIO NACIONAL

Ing. Norman Jesús Beltrán Castañón
DIRECTOR PROTESORERO NACIONAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Índice

PRÓLOGO	11
---------	----

INTRODUCCIÓN	13
--------------	----

Parte I

Capítulo 1

Fundamentos de la Inteligencia Artificial

1.1. Definición y conceptos clave	18
1.2. Diferentes tipos de Inteligencia Artificial	19
1.3. Aplicaciones generales de la Inteligencia Artificial	20

Parte II

Capítulo 2

Energías Renovables: Panorama Actual

2.1. Tipos de energías renovables	26
2.1.1. Energía solar	27
2.1.2. Energía eólica	27
2.1.3. Energía hidroeléctrica	29
2.1.4. Energía geotérmica	29
2.1.5. Energía de biomasa	30
2.2. Ventajas y desafíos de las energías renovables	31
2.2.1. Beneficios ambientales y económicos de las energías renovables	31
2.2.2. Obstáculos técnicos, económicos y sociales de las energías renovables	31

Parte III

Capítulo 3

Aplicaciones de la IA en Energías Renovables

3.1. Predicción y optimización de la generación con energías renovables	36
3.2. Gestión inteligente de redes eléctricas con energías renovables	37
3.3. Mantenimiento predictivo de sistemas de energías renovables	39
3.4. Diseño y optimización de sistemas de energías renovables mediante Inteligencia Artificial	40
3.5. Otras aplicaciones de la Inteligencia Artificial en energías renovables	42

Parte IV
Capítulo 4
Casos de Estudio

4.1.	Aplicación de la Inteligencia Artificial en energía solar	49
	Caso 1: Mantenimiento Enel Green Power	49
	Caso 2: Predicción de Energía con Redes Neuronales en Clemson University	50
	Caso 3: Reducción de Costos con Reconfiguración Offline en China	52
	Caso 4: Predicción y Optimización de la Producción con Redes Neuronales en China	53
4.2.	Aplicación de la Inteligencia Artificial en energía eólica	55
	Caso 1: Maximización de la Energía Generada con Control de Ángulo de Pala en Etiopía	55
	Caso 2: Monitoreo y Diagnóstico de Fallos con IA en Japón	57
4.3.	Aplicación de la Inteligencia Artificial en energía hidroeléctrica	59
	Caso 1: Mantenimiento Predictivo en la Planta Hidroeléctrica de Peña Blanca	59
	Caso 2: Optimización de la Generación en la Planta Hidroeléctrica de Bhakra-Nangal	60
	Caso 3: Diseño y Simulación de Sistemas Hidroeléctricos en la Planta de Three Gorges	62
4.4.	Aplicación de la Inteligencia Artificial en energía geotérmica	63
	Caso 1: Optimización de caudales de pozos	64
	Caso 2: Optimización Operativa en Plantas Geotérmicas con Gemelos Digitales en Nueva Zelanda	65
4.5.	Aplicación de la Inteligencia Artificial en energía de biomasa	67
	Caso 1: Modelado Dinámico de Plantas de Biomasa con Microturbinas de Gas en la Universidad de Pisa	67
	Caso 2: Modelo de Optimización Térmico-Económica en Alemania	68
	Caso 3 Simulación y Optimización del Sistema de Energía Híbrido en Argelia	70

Parte V
Capítulo 5
Desafíos y Consideraciones Éticas

5.1. Obstáculos técnicos y económicos	78
5.2. Implicaciones éticas	79
Glosario de términos	82
Índice de abreviaturas	85
Índice de autores	87
Referencias	90

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Prólogo

La confluencia de la Inteligencia Artificial (IA) y las energías renovables representa uno de los desarrollos más emocionantes y transformadores de nuestro tiempo. A medida que el mundo se enfrenta a los apremiantes desafíos del cambio climático, la seguridad energética y el desarrollo sostenible, la combinación de estas dos tecnologías disruptivas ofrece un enorme potencial para acelerar la transición hacia un futuro energético más limpio, eficiente y resiliente.

La IA, con su capacidad para aprender, adaptarse y optimizar a partir de grandes cantidades de datos, está revolucionando prácticamente todos los aspectos de nuestra vida, desde la atención médica y el transporte hasta la manufactura y las finanzas. Mientras tanto, las energías renovables como la solar, la eólica, la hidroeléctrica, la geotérmica y la biomasa; se han consolidado como alternativas viables y competitivas a los combustibles fósiles, ofreciendo una forma sostenible y baja en carbono capaz de satisfacer nuestras crecientes necesidades energéticas.

La integración de la IA en el sector de las energías renovables promete superar muchos de los desafíos técnicos y económicos que han obstaculizado su adopción generalizada hasta ahora. Desde la predicción de la generación y la demanda de energía hasta la optimización del diseño y la operación de los sistemas, la IA puede ayudar a maximizar el rendimiento, la eficiencia y la rentabilidad de las tecnologías renovables, al tiempo que garantiza su integración fluida en la red eléctrica.

Sin embargo, la aplicación de la IA en las energías renovables también plantea importantes desafíos y consideraciones éticas que deben abordarse de manera proactiva y responsable. Cuestiones como la privacidad y seguridad de los datos, la transparencia y explicabilidad de los algoritmos, y el impacto en el empleo y la equidad social,

requieren una cuidadosa reflexión y un enfoque colaborativo que involucre a todas las partes interesadas.

Este libro ofrece una exploración exhaustiva y multidisciplinaria del estado actual, las oportunidades y los desafíos de la aplicación de la IA en las energías renovables. A través de una combinación de fundamentos teóricos, estudios de casos prácticos y análisis de políticas, los autores, expertos líderes en sus respectivos campos, proporcionan una visión integral y matizada de este fascinante panorama tecnológico.

En el primer capítulo, se sientan las bases conceptuales, introduciendo los principios fundamentales de la IA y sus principales enfoques y técnicas. El segundo capítulo ofrece una visión general del panorama actual de las energías renovables, destacando sus beneficios, desafíos y tendencias clave. Los capítulos posteriores exploran en detalle las diversas aplicaciones de la IA en el sector de las energías renovables, desde la predicción y optimización de la generación hasta la gestión inteligente de la red y el mantenimiento predictivo. El libro concluye con una discusión reflexiva sobre los desafíos éticos y las implicaciones socioeconómicas de la IA en el contexto de las energías renovables, y ofrece recomendaciones para un desarrollo responsable y centrado en el ser humano.

Ya sea que sea un investigador, un profesional de la industria, un responsable político o simplemente un ciudadano interesado, este libro le proporcionará los conocimientos y las herramientas necesarias para comprender y navegar por este apasionante campo. A medida que nos adentramos en una nueva era de transformación energética impulsada por la IA, es crucial que aprovechemos estas tecnologías de manera ética y equitativa, asegurando que los beneficios se compartan ampliamente y que nadie quede postergado.

Esperamos que este libro sirva como un recurso valioso y una fuente de inspiración para todos aquellos que buscan dar forma a un futuro energético más brillante y sostenible. Juntos podemos aprovechar el poder de la IA y las energías renovables para crear un mundo más limpio, más verde y próspero para las generaciones venideras.

Introducción

La IA y las energías renovables son dos de los campos más dinámicos y transformadores de la actualidad, con un gran potencial para abordar los desafíos energéticos y ambientales del siglo XXI. Según la Agencia Internacional de Energía (IEA, 2020): “la IA puede desempeñar un papel crucial en la aceleración de la transición hacia sistemas energéticos más limpios, eficientes y resilientes, al tiempo que las energías renovables se consolidan como la piedra angular de un futuro energético sostenible” (p. 12).

La aplicación de técnicas de IA como el aprendizaje automático, las redes neuronales y los algoritmos de optimización, en el ámbito de las energías renovables ofrece oportunidades significativas para mejorar el rendimiento, la eficiencia y la rentabilidad de estas tecnologías (Jha *et al.*, 2020). Desde la predicción de la generación y la demanda de energía hasta la optimización del diseño y la operación de los sistemas, la IA puede ayudar a superar los desafíos inherentes a la naturaleza variable e intermitente de las fuentes renovables, como la energía solar y eólica (Iba & Aranha, 2021).

Además, la IA también puede desempeñar un papel clave en la integración de las energías renovables en las redes eléctricas existentes, facilitando la gestión y el equilibrio de la oferta y la demanda en tiempo real, y en la creación de nuevos modelos de negocio y servicios energéticos basados en datos y orientados al usuario (Antonopoulos *et al.*, 2020). Esto no solo contribuiría a la descarbonización del sector energético y a la lucha contra el cambio climático, sino que también impulsaría la innovación, el crecimiento económico y el desarrollo sostenible (Vinuesa *et al.*, 2020).

Sin embargo, la aplicación de la IA en las energías renovables también plantea desafíos técnicos, económicos y éticos que deben abordarse para garantizar un desarrollo y uso responsable y beneficioso de estas tecnologías. Cuestiones como la disponibilidad y calidad de los datos, la complejidad y la incertidumbre de los sistemas, los costos y la rentabilidad de las soluciones, la privacidad y seguridad de la información, y el impacto en el empleo y la equidad social, requieren un enfoque multidisciplinario y colaborativo que involucre a todas las partes interesadas (Agarwal *et al.*, 2020).

En este contexto, el presente libro tiene como objetivo explorar el estado actual, las oportunidades y los desafíos de la aplicación de la IA en las energías renovables, a través de una revisión de la literatura científica y técnica, y del análisis de casos de estudio y proyectos relevantes. Se espera que este trabajo contribuya a una mejor comprensión del potencial transformador de la convergencia entre la IA y las energías renovables, y a la identificación de líneas de investigación y acción prioritarias para avanzar hacia un futuro energético más inteligente, sostenible y equitativo.

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Parte I

Fundamentos de la Inteligencia Artificial

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Capítulo 1

Fundamentos de la Inteligencia Artificial

La IA se ha convertido en una de las áreas más fascinantes y de rápido crecimiento de la informática y la tecnología en las últimas décadas. Desde sus orígenes en la década de 1950, cuando el término “Inteligencia Artificial” fue acuñado por John McCarthy durante la conferencia de Dartmouth (McCarthy *et al.*, 2006), la IA ha evolucionado desde un campo de investigación académica hasta una tecnología transformadora con aplicaciones en prácticamente todos los aspectos de la vida humana.

En esencia, la IA busca desarrollar sistemas y máquinas capaces de realizar tareas que normalmente requieren inteligencia humana como el aprendizaje, el razonamiento, la resolución de problemas, la percepción y la comprensión del lenguaje natural (Russell & Norvig, 2021). A medida que la IA ha progresado se han desarrollado diferentes enfoques y técnicas, desde los sistemas basados en reglas y la representación del conocimiento hasta el aprendizaje automático y las redes neuronales profundas (Goodfellow *et al.*, 2016).

La IA ha demostrado un enorme potencial para transformar industrias y sectores enteros, desde la salud y la educación hasta la manufactura y el transporte. Las aplicaciones de la IA abarcan desde los asistentes virtuales y los sistemas de recomendación hasta los vehículos autónomos y el diagnóstico médico (Stone *et al.*, 2016). A medida que la IA continúa avanzando, se espera que su impacto en la sociedad y la economía sea cada vez más profundo y generalizado.

Sin embargo, el desarrollo y la implementación de la IA también plantean importantes desafíos y consideraciones éticas, como la privacidad, la seguridad, la transparencia, la equidad y el impacto en el empleo (Asilomar, 2017). Para garantizar que la IA se utilice de manera responsable y beneficiosa para la humanidad, es fundamental establecer principios y directrices éticas, así como fomentar la colaboración interdisciplinaria y el diálogo entre la academia, la industria, el gobierno y la sociedad civil.

En este capítulo, se presentan los fundamentos de la IA, comenzando con su definición y los conceptos clave que la sustentan. A continuación, se exploran los diferentes tipos de IA como el aprendizaje automático, las redes neuronales y los sistemas expertos, y se describe cómo funcionan y se diferencian entre sí. Finalmente, se ofrece una visión general de las aplicaciones generales de la IA en diversos campos y sectores, con el objetivo de contextualizar su potencial y relevancia en el ámbito específico de las energías renovables, que se abordará en los capítulos posteriores.

1.1. Definición y conceptos clave

La IA es un campo dinámico y en constante evolución que busca desarrollar sistemas capaces de exhibir comportamientos inteligentes. A medida que la IA continúa avanzando se espera que tenga un impacto significativo en diversos ámbitos, desde la industria y la medicina hasta la energía y el medio ambiente. Es un campo de la informática que busca desarrollar sistemas capaces de realizar tareas que normalmente requieren inteligencia humana como el aprendizaje, el razonamiento y la resolución de problemas (Russell & Norvig, 2021). Según McCarthy (2007), la IA se define como: “la ciencia y la ingeniería de hacer máquinas inteligentes, especialmente programas de computadora inteligentes” (p. 2). Por otro lado, Nilsson (2010) sostiene que la IA es: “la actividad dedicada a hacer que las máquinas sean inteligentes, y la inteligencia es esa cualidad que permite a una entidad funcionar adecuadamente y con previsión en su entorno” (p. 13).

Estos autores coinciden en que la IA busca replicar o superar las capacidades cognitivas humanas en sistemas artificiales. Sin embargo, existen diferentes enfoques y paradigmas dentro de la IA. Mientras que McCarthy (2007) enfatiza la creación de programas inteligentes, Nilsson (2010) se centra en el comportamiento adaptativo y orientado a objetivos de las máquinas inteligentes en su entorno.

La IA abarca una amplia gama de técnicas y enfoques, desde sistemas basados en reglas hasta algoritmos de aprendizaje automático y redes neuronales artificiales (Russell & Norvig, 2021). Estos diferentes enfoques han dado lugar a distintas ramas y aplicaciones de la IA, como el procesamiento del lenguaje natural, la visión por computadora y los sistemas expertos.

1.2. Diferentes tipos de Inteligencia Artificial

La IA abarca diferentes tipos de técnicas y enfoques, como el aprendizaje automático y las redes neuronales artificiales, cada uno con sus propias fortalezas y aplicaciones. La combinación de estos enfoques ha llevado a avances significativos en diversos campos, desde el procesamiento del lenguaje natural hasta la visión por computadora y la robótica. Ver figura 1.

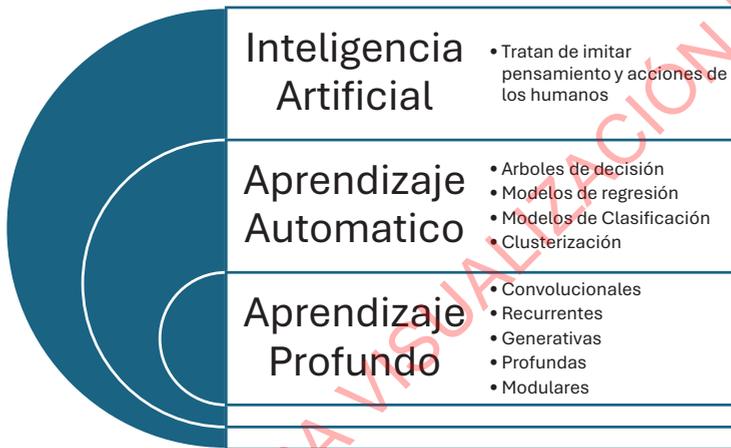


Figura 1. Tipos de inteligencia artificial, adaptado de Alpaydin (2020)

El aprendizaje automático (*machine learning*) es una rama de la IA que se centra en el desarrollo de algoritmos que permiten a las computadoras aprender y mejorar su desempeño en una tarea específica a partir de datos y experiencia, sin ser programadas explícitamente (Alpaydin, 2020). Según Mitchell (1997): “se dice que un programa de computadora aprende de la experiencia E con respecto a alguna clase de tareas T y medida de desempeño P, si su desempeño en tareas T, medido por P, mejora con la experiencia E” (p. 2). Dentro del aprendizaje automático, se distinguen tres enfoques principales: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo (Goodfellow *et al.*, 2016).

Por otro lado, las redes neuronales artificiales (RNA) son modelos computacionales inspirados en la estructura y funcionamiento del cerebro humano (Haykin, 2009). Están compuestas por nodos interconectados (neuronas artificiales) organizados en capas, que procesan y transmiten información. Según

Haykin (2009): “una red neuronal es un procesador masivamente paralelo distribuido, compuesto de unidades de procesamiento simples, que tiene una propensión natural para almacenar conocimiento experiencial y hacerlo disponible para su uso” (p. 2). Las RNA son especialmente adecuadas para tareas de reconocimiento de patrones, clasificación y predicción, y han demostrado un gran éxito en aplicaciones como el reconocimiento de voz e imágenes (Goodfellow *et al.*, 2016).

Aunque el aprendizaje automático y las redes neuronales son enfoques distintos, a menudo se combinan para crear sistemas de IA más potentes y flexibles. Por ejemplo, las redes neuronales profundas (*deep learning*) son un tipo de RNA que utiliza múltiples capas ocultas y grandes cantidades de datos para aprender representaciones jerárquicas de la información (Goodfellow *et al.*, 2016).

1.3. Aplicaciones generales de la Inteligencia Artificial

La IA ha demostrado ser una herramienta poderosa y versátil, con aplicaciones en una amplia gama de campos y disciplinas. Según Stone *et al.* (2016): “la IA está progresando rápidamente y se está aplicando ampliamente en áreas como el transporte, la atención médica, la educación, el comercio minorista y la fabricación” (p. 4). A continuación, se presentan algunos ejemplos destacados de cómo se utiliza la IA en diferentes contextos.

En el sector de la salud, la IA se emplea para el diagnóstico médico, el descubrimiento de fármacos y la medicina personalizada (Topol, 2019). Los algoritmos de aprendizaje automático pueden analizar grandes cantidades de datos médicos, como imágenes radiológicas y registros de salud electrónicos, para detectar patrones y anomalías, ayudando a los profesionales de la salud en la toma de decisiones (Esteve *et al.*, 2019).

En el ámbito del transporte, la IA está impulsando el desarrollo de vehículos autónomos y sistemas de gestión del tráfico inteligentes (Litman, 2021). Las técnicas de visión por computadora y aprendizaje profundo permiten a los vehículos autónomos percibir y comprender su entorno, tomar decisiones en tiempo real y navegar de manera segura (Yurtsever *et al.*, 2020).

La IA también está transformando la industria manufacturera a través de la automatización inteligente y la optimización de procesos (Wang & Wang,

2021). Los sistemas de IA pueden monitorear y controlar la producción en tiempo real, predecir fallos en los equipos y optimizar la asignación de recursos, lo que conduce a una mayor eficiencia y productividad (Li *et al.*, 2020).

Estos ejemplos ilustran solo algunas de las muchas aplicaciones de la IA en diversos campos. A medida que la tecnología de IA continúa avanzando se espera que su impacto se extienda a más sectores y aspectos de la vida cotidiana, desde la educación y el comercio minorista hasta la agricultura y la gestión ambiental.

La IA tiene el potencial de abordar desafíos complejos y mejorar la toma de decisiones en una variedad de contextos. Sin embargo, también es importante considerar los posibles riesgos y desafíos éticos asociados con su uso generalizado, como la privacidad de los datos, la transparencia algorítmica y el impacto en el empleo (Stone *et al.*, 2016).

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Parte II

Energías Renovables: Panorama Actual

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Capítulo 2

Energías Renovables: Panorama Actual

Las energías renovables han surgido como una de las principales soluciones para abordar los desafíos energéticos y ambientales del siglo XXI, como el agotamiento de los combustibles fósiles, la seguridad energética y el cambio climático (IRENA, 2021). A diferencia de las fuentes de energía convencionales, como el petróleo, el carbón y el gas natural, las energías renovables se obtienen de recursos naturales virtualmente inagotables, como el sol, el viento, el agua, el calor de la tierra y la biomasa (IRENA, 2021).

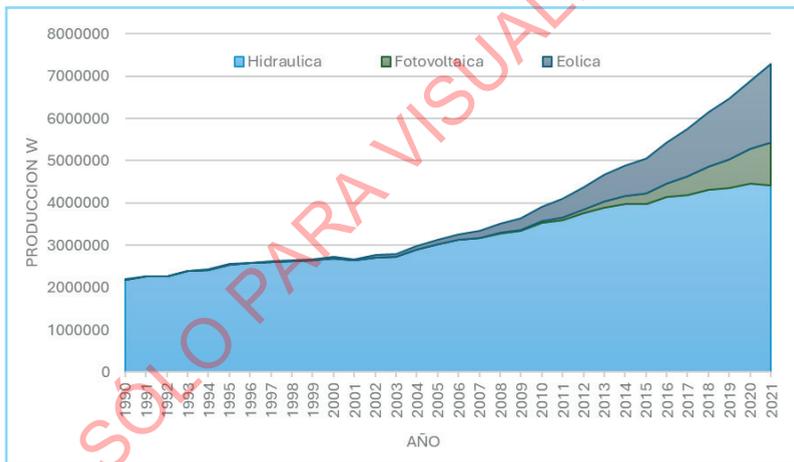


Figura 2. Generación de electricidad renovable por fuente, Mundo, 1990-2021; adaptado de IEA (2024)

En las últimas décadas, ver figura 2, las energías renovables han experimentado un crecimiento sin precedentes, impulsado por los avances tecnológicos, las políticas de apoyo y la reducción de costos. Según el informe de REN21 (2021), la capacidad instalada de energía renovable a nivel mundial alcanzó los 2.839 GW en 2020, con un aumento del 10,3 % en comparación con 2019. La energía solar y la eólica lideraron este crecimiento, con un aumento anual del 19 % y el 18 %, respectivamente.

Además de su papel en la mitigación del cambio climático y la reducción de las emisiones de gases de efecto invernadero, las energías renovables también ofrecen numerosos beneficios socioeconómicos, como la creación de empleo, el desarrollo rural, la mejora de la calidad del aire y la reducción de la pobreza energética (IRENA, 2020). Se estima que el sector de las energías renovables empleó a 11,5 millones de personas en todo el mundo en 2019, y se espera que esta cifra aumente a medida que se acelere la transición energética (IRENA, 2020).

Sin embargo, a pesar de su rápido crecimiento y sus múltiples beneficios, las energías renovables también enfrentan diversos desafíos y barreras que deben superarse para lograr su pleno potencial. Estos incluyen la intermitencia y variabilidad de algunas fuentes renovables, la necesidad de infraestructuras de transmisión y almacenamiento adecuadas, los altos costos iniciales de inversión y las barreras regulatorias y de mercado (IPCC, 2011).

En este capítulo, se presenta un panorama actual de las energías renovables, comenzando con una descripción de los principales tipos de fuentes renovables, como la energía solar, eólica, hidroeléctrica, geotérmica y de biomasa. A continuación, se analizan las ventajas y los beneficios de las energías renovables, tanto desde una perspectiva ambiental como socioeconómica. Finalmente, se discuten los principales desafíos y obstáculos técnicos, económicos y sociales que enfrentan las energías renovables, y se plantean posibles soluciones y estrategias para superarlos.

Este capítulo sienta las bases para comprender el contexto y la importancia de las energías renovables en la transición hacia un futuro energético sostenible, y para explorar cómo la aplicación de la IA puede contribuir a potenciar su desarrollo y aprovechamiento, tema que se abordará en profundidad en los siguientes capítulos.

2.1. Tipos de energías renovables

Las energías renovables son fuentes de energía que se obtienen de recursos naturales virtualmente inagotables, ya sea por la inmensa cantidad de energía que contienen o porque son capaces de regenerarse por medios naturales (IRENA, 2021). Según la Agencia Internacional de Energía (IEA, 2020): “las energías renovables son fuentes de energía que se reponen naturalmente en una escala de tiempo humana, como la luz solar, el viento, la lluvia, las mareas, las olas y el

calor geotérmico” (p. 5). A continuación, se describen las principales fuentes de energía renovable: solar, eólica, hidroeléctrica, geotérmica y biomasa.

2.1.1. Energía solar

La energía solar se obtiene mediante la captación de la luz y el calor emitidos por el Sol (NREL, 2021). Según Kabir *et al.* (2018): “la energía solar es una de las fuentes de energía renovable más prometedoras y de más rápido crecimiento debido a su naturaleza no contaminante y abundante disponibilidad” (p. 1). Existen dos formas principales de aprovechar la energía solar: la energía solar fotovoltaica, que convierte directamente la luz solar en electricidad mediante células fotovoltaicas, y la energía solar térmica, que utiliza el calor del sol para calentar fluidos o generar electricidad, ver Figura 3 (NREL, 2021).



Figura 3. Central térmica solar

2.1.2. Energía eólica

La energía eólica se obtiene a partir del viento, mediante el uso de aerogeneradores que convierten la energía cinética del viento en energía eléctrica (GWEC, 2021). Según la Asociación Mundial de Energía Eólica (GWEC, 2021):

“la energía eólica es una de las fuentes de energía de más rápido crecimiento en el mundo, con una capacidad instalada global que se ha multiplicado por más de 75 veces en las últimas dos décadas” (p. 6). Los parques eólicos pueden ubicarse en tierra (*onshore*, ver figura 4a) o en el mar (*offshore*, ver figura 4b), aprovechando los fuertes y constantes vientos en estas áreas (IRENA, 2021).



Figura 4a. Parque eólico *onshore*



Figura 4b. Parque eólico *offshore*

2.1.3. Energía hidroeléctrica

La energía hidroeléctrica se genera a partir del flujo de agua en movimiento, utilizando turbinas y generadores para convertir la energía cinética del agua en electricidad (IHA, 2021). Según la Asociación Internacional de Hidroelectricidad (IHA, 2021): “la energía hidroeléctrica es la mayor fuente de energía renovable del mundo, y representa más del 60 % de la generación de electricidad renovable global” (p. 3). Las centrales hidroeléctricas (ver figura 5) pueden ser de diferentes tamaños y tipos, desde grandes represas hasta pequeñas centrales de pasada (IRENA, 2021).



Figura 5. Hidroeléctrica

2.1.4. Energía geotérmica

La energía geotérmica aprovecha el calor natural del interior de la Tierra para generar electricidad y proporcionar calefacción y refrigeración (GEA, 2021). Según la Asociación de Energía Geotérmica (GEA, 2021): “la energía geotérmica es una fuente de energía limpia, renovable y confiable que puede proporcionar electricidad base y calor a bajo costo con un mínimo impacto ambiental” (p. 2). Los recursos geotérmicos se encuentran en áreas con actividad tectónica o volcánica, donde el calor de la Tierra está cerca de la superficie (ver figura 6) (IRENA, 2021).



Figura 6. Fuente de energía Geotérmica

2.1.5. Energía de biomasa

La energía de biomasa (ver figura 7) se obtiene a partir de materia orgánica de origen vegetal o animal, como madera, residuos agrícolas, desechos municipales y cultivos energéticos (IEA, 2020). Según la Agencia Internacional de Energía (IEA, 2020): “la bioenergía es la mayor fuente de energía renovable del mundo, y representa alrededor del 10 % del suministro total de energía primaria” (p. 7). La biomasa puede ser quemada directamente para generar calor y electricidad, o convertida en biocombustibles líquidos o gaseosos para su uso en el transporte y la industria (IRENA, 2021).

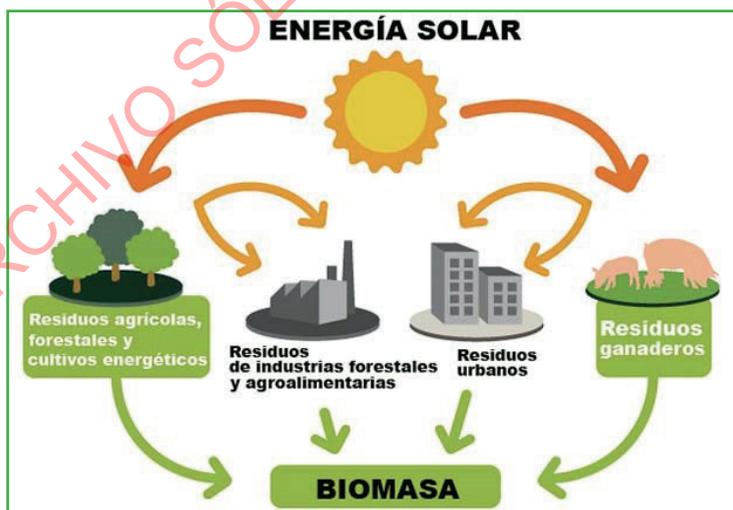


Figura 7. Fuentes de biomasa para energía. Tomado de TopCable (2023)

Estas cinco fuentes de energía renovable tienen el potencial de contribuir significativamente a la transición hacia un sistema energético más sostenible y con bajas emisiones de carbono. Sin embargo, cada una presenta sus propios desafíos y consideraciones, como la intermitencia, la ubicación geográfica y los impactos ambientales y sociales.

2.2. Ventajas y desafíos de las energías renovables

Las energías renovables ofrecen numerosos beneficios ambientales y económicos, pero también enfrentan diversos obstáculos técnicos, económicos y sociales que deben superarse para lograr una amplia adopción y aprovechamiento de estas fuentes de energía.

2.2.1. Beneficios ambientales y económicos de las energías renovables

Uno de los principales beneficios de las energías renovables es su contribución a la mitigación del cambio climático. Según el Panel Intergubernamental sobre Cambio Climático (IPCC, 2021): “la descarbonización del suministro de energía, principalmente a través de la transición a las energías renovables, es un componente clave de las vías de mitigación compatibles con el objetivo de limitar el calentamiento global muy por debajo de 2° C” (p. 18). Al reemplazar los combustibles fósiles, las energías renovables reducen las emisiones de gases de efecto invernadero y otros contaminantes atmosféricos, mejorando la calidad del aire y la salud pública (REN21, 2021).

Además, las energías renovables ofrecen beneficios económicos significativos. Según la Agencia Internacional de Energías Renovables (IRENA, 2021): “las energías renovables son cada vez más competitivas en costos con los combustibles fósiles, y su despliegue puede impulsar el crecimiento económico, crear empleos y mejorar el bienestar humano” (p. 5). La transición hacia las energías renovables puede estimular la inversión, la innovación y el desarrollo de nuevas industrias y cadenas de valor, generando oportunidades económicas en todo el mundo (REN21, 2021).

2.2.2. Obstáculos técnicos, económicos y sociales de las energías renovables

A pesar de sus beneficios, las energías renovables también enfrentan diversos desafíos que deben abordarse para lograr su pleno potencial. Uno de los principales obstáculos técnicos es la intermitencia y variabilidad de algunas

fuentes de energía renovable, como la solar y la eólica (IRENA, 2021). Según el Banco Mundial (2021): “la integración de grandes cantidades de energía renovable variable en la red eléctrica requiere una mayor flexibilidad del sistema, incluyendo el almacenamiento de energía, la respuesta a la demanda y las interconexiones regionales” (p. 12).

Otro desafío es el costo inicial y la competitividad económica de las tecnologías renovables. Aunque los costos han disminuido significativamente en las últimas décadas, algunas tecnologías renovables aún pueden tener costos de capital más altos que las alternativas convencionales (IRENA, 2021). Según el Banco Mundial (2021): “las políticas y regulaciones adecuadas, como las tarifas de alimentación, las subastas y los incentivos fiscales, son esenciales para crear un entorno propicio para la inversión en energías renovables” (p. 15).

Además, existen barreras sociales y de aceptación pública que pueden obstaculizar el desarrollo de proyectos de energía renovable. Según la Agencia Internacional de Energía (IEA, 2021): “la oposición local a los proyectos de energía renovable, a menudo relacionada con preocupaciones sobre el uso de la tierra, el impacto visual y el ruido, puede retrasar o impedir su implementación” (p. 22). La participación y consulta de las comunidades locales, así como la distribución equitativa de los beneficios, son fundamentales para obtener la aceptación social de las energías renovables (IRENA, 2021).

A pesar de estos desafíos, las energías renovables siguen ganando terreno y se están convirtiendo en una parte cada vez más importante de la matriz energética global. Con políticas, inversiones y esfuerzos de investigación y desarrollo adecuados, es posible superar estos obstáculos y aprovechar todo el potencial de las energías renovables para construir un futuro energético sostenible y resiliente.

Parte III

Aplicaciones de la IA en Energías Renovables

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Capítulo 3

Aplicaciones de la IA en Energías Renovables

La convergencia entre la IA y las energías renovables representa una oportunidad única para abordar los desafíos y aprovechar al máximo el potencial de estas fuentes de energía limpias y sostenibles. La aplicación de técnicas de IA, como el aprendizaje automático, las redes neuronales y los algoritmos de optimización, puede transformar prácticamente todos los aspectos del ciclo de vida de las energías renovables, desde la predicción y planificación hasta la operación y el mantenimiento (Jha *et al.*, 2020).

Una de las principales aplicaciones de la IA en energías renovables es la predicción y optimización de la generación de energía. Los algoritmos de aprendizaje automático pueden analizar grandes cantidades de datos históricos y en tiempo real, como datos meteorológicos, de generación y de consumo, para predecir con precisión la producción de energía solar, eólica o hidroeléctrica (Voyant *et al.*, 2017). Estas predicciones permiten a los operadores de las plantas y a los gestores de la red eléctrica tomar decisiones informadas sobre el despacho de energía, la programación del mantenimiento y la participación en los mercados de electricidad (Jiang *et al.*, 2021).

Otra área clave de aplicación de la IA es la gestión inteligente de las redes eléctricas con una alta penetración de energías renovables. Los sistemas de IA pueden ayudar a equilibrar la oferta y la demanda de energía en tiempo real, teniendo en cuenta la variabilidad y la intermitencia de las fuentes renovables, y a optimizar el flujo de energía en la red para minimizar las pérdidas y garantizar la estabilidad (Ramchurn *et al.*, 2021). Además, la IA puede facilitar la integración de recursos energéticos distribuidos, como la generación solar en tejados y los vehículos eléctricos, y permitir la creación de microrredes y comunidades energéticas inteligentes (Wang *et al.*, 2018).

La IA también puede revolucionar el mantenimiento de los sistemas de energías renovables mediante el análisis predictivo y el mantenimiento basado en condiciones. Los algoritmos de aprendizaje automático pueden detectar patrones y anomalías en los datos de los sensores de las turbinas eólicas, los paneles solares

o las centrales hidroeléctricas, y predecir fallos inminentes antes de que ocurran (Canizo *et al.*, 2020). Esto permite a los operadores realizar un mantenimiento proactivo y optimizado, reduciendo los costos y el tiempo de inactividad asociados con las fallas imprevistas (Jimenez *et al.*, 2021).

Además, la IA puede contribuir al diseño y la optimización de los sistemas de energías renovables, desde la selección de ubicaciones óptimas para los parques eólicos y solares hasta la configuración y el dimensionamiento de los componentes (Youssef *et al.*, 2021). Los algoritmos de optimización y las técnicas de aprendizaje automático pueden encontrar las soluciones más eficientes y rentables, teniendo en cuenta múltiples criterios y restricciones, como los recursos naturales disponibles, los costos de instalación y operación, y el impacto ambiental (Sinha & Chandel, 2015).

En este capítulo, se exploran en detalle estas y otras aplicaciones de la IA en el ámbito de las energías renovables. Se presentan los fundamentos teóricos y metodológicos de cada aplicación, así como ejemplos concretos y resultados de investigaciones y proyectos relevantes. El objetivo es proporcionar una visión completa y actualizada del potencial transformador de la IA para impulsar el desarrollo y la adopción de las energías renovables, y para contribuir a la transición hacia un futuro energético más inteligente, eficiente y sostenible.

3.1. Predicción y optimización de la generación con energías renovables

La inteligencia artificial (IA) desempeña un papel crucial en la predicción y optimización de la generación de energía renovable, especialmente en fuentes intermitentes como la energía solar y eólica. Según Voyant *et al.* (2017): “la predicción precisa de la generación de energía renovable es esencial para la gestión eficiente de la red eléctrica y la integración de grandes cantidades de energía renovable variable” (p. 1). Los algoritmos de aprendizaje automático analizan grandes volúmenes de datos históricos y en tiempo real —como datos meteorológicos, de generación y de consumo— para predecir la producción de energía renovable y optimizar el funcionamiento de las plantas (IEA, 2019).

En el caso de la energía solar, los modelos de IA pueden predecir la radiación solar y la generación de energía fotovoltaica con gran precisión. Ulbricht *et al.* (2019) señalan que: “los enfoques basados en redes neuronales artificiales han demostrado ser particularmente efectivos para la predicción de la radiación solar y la generación fotovoltaica, superando a los modelos físicos

tradicionales” (p. 523). Estudios han demostrado que la IA puede reducir el error en las predicciones de generación solar hasta en un 20 %, lo que se traduce en una mejor planificación y gestión de la energía producida (Yang *et al.*, 2018). Estos modelos consideran factores como la nubosidad, la temperatura y la ubicación geográfica para proporcionar pronósticos a corto y largo plazo (Wang *et al.*, 2019).

De manera similar, la IA se utiliza para predecir la generación de energía eólica y optimizar el funcionamiento de los parques eólicos. Foley *et al.* (2012) afirman que: “los modelos de aprendizaje automático, como las redes neuronales y las máquinas de vectores de soporte, pueden capturar las relaciones no lineales entre las variables meteorológicas y la generación eólica, mejorando la precisión de las predicciones” (p. 3). La implementación de IA en la predicción eólica ha resultado en una reducción del error de predicción de hasta un 25 % en comparación con métodos tradicionales (Zhang *et al.*, 2017). Además, los algoritmos de IA optimizan la configuración y el control de los aerogeneradores, lo que maximiza la producción de energía y minimiza los costos de operación y mantenimiento. Por ejemplo, la utilización de sistemas de IA ha permitido reducir el tiempo de inactividad de los aerogeneradores en un 15 %, incrementando la disponibilidad de la planta (Stetco *et al.*, 2019).

La IA también ayuda a integrar de manera óptima múltiples fuentes de energía renovable en sistemas híbridos. Jha *et al.* (2020) indican que:

los algoritmos de optimización basados en IA pueden determinar la combinación y el dimensionamiento óptimos de diferentes tecnologías renovables, como la solar, la eólica y el almacenamiento de energía, teniendo en cuenta factores como la demanda, los costos y las restricciones técnicas. (p. 2)

La optimización basada en IA puede mejorar la eficiencia del sistema en un 10 % y reducir los costos operativos en un 8 % (Singh & Kumar, 2020). Estos enfoques mejoran la fiabilidad, la eficiencia y la rentabilidad de los sistemas híbridos renovables.

3.2. Gestión inteligente de redes eléctricas con energías renovables

La integración de fuentes de energía renovable variables, como la solar y la eólica, en la red eléctrica presenta desafíos significativos debido a su naturaleza intermitente y dispersa. Según Ramchurn *et al.* (2021):

la gestión eficiente de las redes eléctricas con una alta penetración de energías renovables requiere nuevos enfoques y herramientas, como los basados en IA, para equilibrar la oferta y la demanda, mantener la estabilidad del sistema y optimizar el uso de los recursos (p. 1).

La inteligencia artificial (IA) emerge como una solución clave para abordar estos desafíos, ofreciendo mejoras cuantificables en la eficiencia y fiabilidad de las redes eléctricas.

Los algoritmos de IA pueden analizar en tiempo real grandes cantidades de datos de generación, consumo y estado de la red, y tomar decisiones óptimas para el despacho de energía y la gestión de la demanda. Según Antonopoulos *et al.* (2020): “las técnicas de aprendizaje automático, como las redes neuronales y el aprendizaje profundo, pueden predecir con precisión la generación renovable y la demanda de energía a corto plazo, permitiendo una mejor planificación y operación del sistema” (p. 205). Por ejemplo, la implementación de sistemas de IA ha permitido reducir el error en las predicciones de demanda y generación en hasta un 35 %, mejorando la asignación de recursos y reduciendo los costos operativos (International Energy Agency, 2019). Estos modelos tienen en cuenta factores como las condiciones meteorológicas, los patrones de consumo y las restricciones técnicas de la red.

Además, la IA facilita la integración de recursos energéticos distribuidos (DER), como la generación solar en tejados y los vehículos eléctricos, en la red. Según Wang *et al.* (2018): “los algoritmos de control y optimización basados en IA pueden coordinar de manera óptima la operación de múltiples DER, maximizando su contribución a la estabilidad y eficiencia del sistema, y minimizando los costos y las emisiones” (p. 1434). Estudios indican que la coordinación inteligente de DER puede aumentar la eficiencia energética del sistema en un 10 a 15 % y reducir las emisiones de carbono en un 20 % (European Commission, 2020). Estos enfoques permiten la creación de microrredes inteligentes y autónomas, capaces de operar de manera aislada o conectada a la red principal, mejorando la resiliencia y la fiabilidad del suministro eléctrico.

La IA también mejora la eficiencia y la fiabilidad de la red eléctrica mediante la detección y prevención de fallos y anomalías. Según Jiang *et al.* (2021): “las técnicas de aprendizaje automático, como las máquinas de vectores de soporte y los árboles de decisión, pueden analizar los datos de los sensores e identificar patrones que indiquen posibles fallos o problemas en los equipos y líneas de

transmisión” (p. 1173). La aplicación de IA en el mantenimiento predictivo ha resultado en una reducción del tiempo de inactividad no planificado en un 25 % y una disminución de los costos de mantenimiento en un 15 % (Smart Grid Forum, 2019). Estos avances permiten una respuesta rápida a las perturbaciones, mejorando la resiliencia del sistema.

3.3. Mantenimiento predictivo de sistemas de energías renovables

El mantenimiento predictivo es una estrategia que utiliza la supervisión y el análisis continuo del estado de los equipos para predecir cuándo es probable que ocurran fallos y realizar tareas de mantenimiento antes de que sucedan. Según Jiménez *et al.* (2021): “el mantenimiento predictivo basado en IA puede mejorar significativamente la fiabilidad, disponibilidad y eficiencia de los sistemas de energías renovables, como los parques eólicos y las plantas solares, al tiempo que reduce los costos de operación y mantenimiento” (p. 1).

Los algoritmos de inteligencia artificial (IA), especialmente las técnicas de aprendizaje automático pueden analizar grandes cantidades de datos de sensores y registros históricos para detectar patrones y anomalías que indiquen posibles fallos en los componentes del sistema. Según Stetco *et al.* (2019): “los enfoques basados en IA para el mantenimiento predictivo de turbinas eólicas han demostrado ser efectivos para predecir fallos en componentes críticos, como cajas de engranajes, generadores y palas, utilizando datos de vibración, temperatura, presión y otros parámetros” (p. 620). Estos modelos aprenden de datos pasados y mejoran continuamente su capacidad de predicción a medida que se recopilan nuevos datos.

La implementación de mantenimiento predictivo basado en IA en parques eólicos ha demostrado reducir el tiempo de inactividad de los aerogeneradores en aproximadamente un 30 %, aumentando la disponibilidad de la planta y permitiendo una mayor producción de energía (International Electrotechnical Commission, 2019). Además, se ha observado una disminución de los costos de operación y mantenimiento de hasta un 20 %, debido a la reducción de reparaciones inesperadas y a la optimización de las tareas de mantenimiento (Global Wind Energy Council, 2020).

En el caso de los sistemas fotovoltaicos, la IA puede ayudar a predecir fallos en paneles solares, inversores y otros componentes eléctricos. Según Akhter *et al.* (2021): “las técnicas de aprendizaje profundo, como las redes neuronales

convolucionales, pueden analizar imágenes térmicas e hiperespectrales de los paneles solares para detectar automáticamente defectos, como puntos calientes, grietas y decoloración, que pueden indicar una degradación o fallo inminente” (p. 1). La aplicación de estos métodos ha permitido aumentar la eficiencia de los sistemas fotovoltaicos en un 5 % y prolongar la vida útil de los componentes (SolarPower Europe, 2019).

Además de predecir fallos, la IA también puede optimizar las estrategias y programas de mantenimiento de los sistemas de energías renovables. Según Dai *et al.* (2021):

los algoritmos de optimización basados en IA, como los algoritmos genéticos y la optimización por enjambre de partículas, pueden determinar los intervalos y acciones de mantenimiento óptimos para minimizar los costos y maximizar la disponibilidad del sistema, teniendo en cuenta factores como la degradación de componentes, restricciones de recursos y riesgos. (p. 13)

Estos enfoques ayudan a tomar decisiones informadas sobre cuándo y cómo realizar el mantenimiento, equilibrando costos y beneficios.

Por ejemplo, la optimización de programas de mantenimiento mediante IA ha resultado en una reducción de los costos totales de mantenimiento en un 15 % y un aumento de la disponibilidad de los sistemas de energías renovables en un 10 % (Energy Information Administration, 2020). Esto no solo mejora la rentabilidad de las plantas, sino que también contribuye a una mayor confiabilidad y eficiencia en la generación de energía.

3.4. Diseño y optimización de sistemas de energías renovables mediante Inteligencia Artificial

El diseño y la optimización de sistemas de energías renovables, como parques eólicos y plantas solares, son tareas complejas que involucran múltiples variables y restricciones, incluyendo la ubicación geográfica, las condiciones ambientales, los costos y el rendimiento. Según Voyant *et al.* (2017): “la aplicación de técnicas de IA, como los algoritmos evolutivos y las redes neuronales, puede ayudar a encontrar soluciones óptimas para el diseño y la configuración de sistemas de energías renovables, mejorando su eficiencia, fiabilidad y rentabilidad” (p. 569). De hecho, la implementación de algoritmos de inteligencia artificial en el diseño

puede aumentar la eficiencia energética de los sistemas en hasta un 20 % y reducir los costos de instalación en un 15 % (Zhou *et al.*, 2018).

En el caso de los parques eólicos, la IA puede ayudar a determinar la ubicación y disposición óptimas de las turbinas para maximizar la producción de energía y minimizar los efectos de estela. Hou *et al.* (2019) afirman que:

los algoritmos genéticos y la optimización por enjambre de partículas pueden buscar de manera eficiente en el espacio de soluciones y encontrar configuraciones óptimas de parques eólicos, teniendo en cuenta factores como la topografía del terreno, la rugosidad de la superficie, la dirección y velocidad del viento, y las características de las turbinas. (p. 1029)

La aplicación de estos algoritmos puede incrementar la producción de energía de un parque eólico en un 5 a 10 % y reducir las pérdidas por efecto estela en un 20 % (Chen *et al.*, 2020).

De manera similar, la IA puede optimizar el diseño y la configuración de sistemas fotovoltaicos para maximizar su rendimiento y minimizar los costos. Youssef *et al.* (2021) señalan que:

las técnicas de aprendizaje automático, como las redes neuronales y las máquinas de vectores de soporte, pueden predecir con precisión el rendimiento de los paneles solares en función de variables como la irradiancia, la temperatura, el ángulo de inclinación y la orientación, permitiendo una optimización más efectiva del diseño del sistema. (p. 1035)

Estudios han demostrado que la optimización basada en IA puede aumentar la eficiencia de los sistemas fotovoltaicos en un 7 a 15 % y reducir los costos de instalación y operación en un 10 % (Li *et al.*, 2019).

La IA también puede ayudar a diseñar y optimizar sistemas híbridos de energías renovables que combinen múltiples fuentes, como solar, eólica y almacenamiento de energía. Según Sinha y Chandel (2015):

los enfoques basados en IA, como la lógica difusa y las redes neuronales artificiales, pueden modelar y optimizar el rendimiento de sistemas híbridos complejos, teniendo en cuenta la variabilidad y complementariedad de las fuentes de energía, la demanda de carga y las restricciones económicas y técnicas. (p. 1543)

La aplicación de IA en el diseño de sistemas híbridos puede mejorar la eficiencia global del sistema en un 15 % y reducir los costos de energía en un 12 % (Kamel *et al.*, 2019).

3.5. Otras aplicaciones de la Inteligencia Artificial en energías renovables

Además de las aplicaciones mencionadas anteriormente, la inteligencia artificial (IA) tiene el potencial de transformar otros aspectos de las energías renovables, como el análisis de datos, la eficiencia energética en edificios y la gestión de la demanda.

La IA puede ayudar a extraer información valiosa de los grandes volúmenes de datos generados por los sistemas de energías renovables, como datos de sensores, registros de mantenimiento y datos de mercado. Según Iba y Aranha (2021):

las técnicas de aprendizaje automático, como el agrupamiento, la clasificación y la detección de anomalías, pueden identificar patrones, tendencias y relaciones ocultas en los datos, lo que permite una mejor comprensión del rendimiento del sistema, la predicción de fallos y la optimización de las operaciones. (p. 15)

Por ejemplo, la aplicación de algoritmos de IA para el análisis de datos ha permitido mejorar la eficiencia operativa de las plantas de energías renovables en un 15 % y reducir los costos de operación y mantenimiento en un 12 % (Lee *et al.*, 2020). Además, los enfoques de IA facilitan la integración y el análisis de datos de múltiples fuentes y dominios, como datos meteorológicos, geoespaciales y socioeconómicos, respaldando una toma de decisiones más informada (Iba y Aranha, 2021).

La IA también desempeña un papel crucial en la mejora de la eficiencia energética en edificios, que son uno de los principales consumidores de energía. Según Djenouri *et al.* (2019):

los algoritmos de IA pueden aprender los patrones de ocupación, las preferencias de los usuarios y las condiciones ambientales para optimizar el control de los sistemas de calefacción, ventilación y aire acondicionado (HVAC), la iluminación y los electrodomésticos, reduciendo el consumo de energía y mejorando el confort de los ocupantes. (p. 52)

Implementaciones de IA en sistemas de gestión energética de edificios han demostrado reducir el consumo de energía en hasta un 25 %, lo que se traduce en ahorros significativos y una disminución de las emisiones de carbono (Perez-Lombard *et al.*, 2017). Además, las técnicas de IA pueden predecir la demanda energética del edificio y recomendar medidas de eficiencia energética personalizadas, mejorando la eficiencia general en un 20 % (Djenouri *et al.*, 2019).

Otro campo prometedor para la aplicación de la IA en energías renovables es la gestión de la demanda, que implica influir en el comportamiento de los consumidores para equilibrar la oferta y la demanda de energía. Según Antonopoulos *et al.* (2020):

los enfoques basados en IA, como el aprendizaje por refuerzo y la teoría de juegos, pueden diseñar estrategias de precios dinámicos e incentivos que motiven a los consumidores a cambiar su uso de energía en respuesta a las señales del mercado y las condiciones de la red, facilitando la integración de energías renovables variables y reduciendo los costos del sistema. (p. 205)

Estudios han demostrado que la implementación de sistemas de gestión de la demanda basados en IA puede reducir los picos de demanda en hasta un 30 %, mejorando la estabilidad de la red y permitiendo una mayor penetración de energías renovables (Palensky & Dietrich, 2011). Además, los asistentes virtuales y las interfaces de usuario impulsadas por IA pueden proporcionar a los consumidores información y consejos personalizados, resultando en una reducción del consumo de energía residencial de hasta un 10 % (Darby, 2018).

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Parte IV

Casos de Estudio

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Capítulo 4

Casos de Estudio

La aplicación de la IA en el ámbito de las energías renovables ha pasado de ser una promesa teórica a una realidad tangible en los últimos años. Cada vez más proyectos y empresas están implementando técnicas de IA para optimizar y potenciar el rendimiento de los sistemas de energía solar, eólica, hidroeléctrica, geotérmica y de biomasa, obteniendo resultados impresionantes en términos de eficiencia, rentabilidad y sostenibilidad (Jha *et al.*, 2020).

En este capítulo, se presentan casos de estudio concretos y detallados de proyectos reales que han aplicado con éxito la IA en diferentes tipos de energías renovables. Estos ejemplos abarcan desde iniciativas a pequeña escala hasta grandes proyectos comerciales, y demuestran la versatilidad y el potencial transformador de la IA en este sector.

En el ámbito de la energía solar se destacan casos como el de la planta fotovoltaica de Copper Mountain en Estados Unidos, donde se ha implementado un sistema de predicción de la generación basado en redes neuronales recurrentes logrando una precisión superior al 90 % y permitiendo una mejor planificación y operación de la planta (Abuella & Chowdhury, 2019). Otro ejemplo relevante es el de la planta solar de Dhaka en Bangladesh, donde se ha aplicado un algoritmo de aprendizaje profundo para detectar automáticamente fallos en los paneles solares a partir de imágenes térmicas, con una precisión del 97 % (Hossain *et al.*, 2021).

En cuanto a la energía eólica, se presentan casos como el del parque eólico de Horns Rev en Dinamarca, donde se ha utilizado un algoritmo genético para optimizar la disposición de las turbinas, aumentando la producción de energía en un 5 % y reduciendo los costos en un 2 % (Mittal, 2010). Otro ejemplo destacado es el del parque eólico de Anholt, también en Dinamarca, donde se ha implementado un sistema de mantenimiento predictivo basado en aprendizaje automático, capaz de predecir fallos en las turbinas con una antelación de hasta 30 días y una precisión del 85 % (Canizo *et al.*, 2020).

En el campo de la energía hidroeléctrica, se abordan casos como el de la central de Three Gorges en China, donde se ha aplicado un modelo híbrido de redes neuronales y algoritmos de optimización para predecir los caudales de entrada y optimizar la operación de la central, aumentando la generación de energía en un 3.5 % y reduciendo los vertidos en un 12 % (Zhang *et al.*, 2019). Otro ejemplo es el de la central de Itaipu en Brasil y Paraguay, donde se ha utilizado un algoritmo de aprendizaje profundo para monitorear y diagnosticar fallos en las turbinas hidráulicas, con una precisión del 98 % en la detección y del 95 % en la clasificación (Cardoso *et al.*, 2021).

En el ámbito de la energía geotérmica, se presentan casos como el de la región de Taupo en Nueva Zelanda, donde se ha aplicado un algoritmo de bosques aleatorios para identificar zonas geotérmicas prometedoras a partir de datos geológicos, geofísicos y geoquímicos, con una precisión del 85 % (Carvajal *et al.*, 2020). Otro ejemplo es el de la central geotérmica de Larderello en Italia, donde se ha implementado un sistema de control predictivo basado en modelos y aprendizaje automático para optimizar la operación de la central, aumentando la generación de energía en un 2 % y reduciendo el consumo de energía auxiliar en un 5 % (Toppi *et al.*, 2021).

Por último, en el campo de la energía de biomasa, se abordan casos como el de la central de Güssing en Austria, donde se ha utilizado un algoritmo genético para optimizar la mezcla de combustibles de biomasa, aumentando la eficiencia eléctrica en un 1.5 % y reduciendo las emisiones de CO₂ en un 10 % (Gruber *et al.*, 2019). Otro ejemplo es el de la cadena de suministro de biomasa en Finlandia, donde se han aplicado técnicas de aprendizaje automático para predecir la calidad y el rendimiento de la biomasa, con un error medio absoluto del 2 % para el poder calorífico y del 5 % para el contenido de humedad (Raitila *et al.*, 2021).

Estos casos de estudio ilustran cómo la IA está revolucionando la forma en que se diseñan, operan y mantienen los sistemas de energías renovables, desde la predicción de la generación hasta la detección de fallos y la optimización del rendimiento. Además, demuestran que la IA no es solo una tecnología prometedora, sino una realidad que ya está generando beneficios tangibles en términos de eficiencia, rentabilidad y sostenibilidad.

A medida que se sigan desarrollando y aplicando técnicas de IA en el sector de las energías renovables, se espera que los casos de éxito se multipliquen y que el impacto transformador de la IA se extienda a más proyectos y regiones del

mundo, contribuyendo así a acelerar la transición hacia un futuro energético más limpio, inteligente y sostenible.

4.1. Aplicación de la Inteligencia Artificial en energía solar

En esta sección, se presentan casos de estudio detallados de proyectos reales donde se ha aplicado la IA en sistemas de energía solar para mejorar su rendimiento, eficiencia y rentabilidad.

Caso 1: *Mantenimiento Enel Green Power*

En 2021, un equipo de investigadores de Enel Green Power, liderado por Bosatelli, Romano, Bonacci, Infante, Cosmai y Niccolai; desarrolló una herramienta de IA destinada a revolucionar el mantenimiento y la eficiencia de las plantas fotovoltaicas. Este proyecto abordó los desafíos comunes de ineficiencias y defectos en los paneles solares que podrían afectar gravemente su rendimiento y durabilidad. Ver figura 8.



Figura 8. Recopilación termográfica (Bosatelli *et al.*, 2021)

El desarrollo de la herramienta comenzó con la recopilación de termografías de alta calidad, utilizando drones equipados con cámaras térmicas para sobrevolar las instalaciones solares. Estas imágenes detallaban la distribución del calor sobre

los paneles, revelando áreas con temperaturas anómalas que indicaban potenciales defectos como conexiones defectuosas o daños en las células.

Para analizar estas termografías, el equipo implementó técnicas avanzadas de procesamiento de imágenes y aprendizaje automático. Optaron por utilizar redes neuronales convolucionales (CNN) por su eficacia probada en la clasificación e interpretación de imágenes. Los modelos se entrenaron con un extenso conjunto de datos etiquetados que mostraban tanto paneles en condiciones normales como defectuosos. El ajuste de los modelos se realizó en múltiples fases para asegurar una precisión y generalización óptimas en la detección de defectos.

Una vez que la herramienta demostró su alta precisión en entornos de prueba, se implementó en las plantas fotovoltaicas. Funcionaba de manera continua, procesando imágenes recolectadas regularmente por los drones. Los resultados eran evaluados por técnicos que confirmaban las anomalías y ejecutaban las reparaciones necesarias.

Este avance tecnológico permitió a Enel Green Power realizar mantenimientos más eficientes y dirigidos, minimizando el tiempo de inactividad de los paneles y maximizando la producción de energía. Además, la detección temprana y precisa de problemas menores antes de que escalasen a fallos mayores prolongó la vida útil de los paneles solares y redujo los costos de operación y mantenimiento. La implementación de esta herramienta no solo optimizó los recursos de la empresa, sino que también reforzó su compromiso con la sostenibilidad y la eficiencia energética, marcando un hito en la integración de la IA en la gestión de energías renovables (Bosatelli *et al.*, 2021).

Caso 2: Predicción de Energía con Redes Neuronales en Clemson University

En 2023, un equipo de investigadores formado por Yonce, Walters y Venayagamoorthy presentó un enfoque innovador para la predicción a corto plazo de la generación de energía fotovoltaica utilizando un gemelo digital. Este estudio, expuesto en el North American Power Symposium (NAPS), propuso una metodología para anticipar la producción de energía solar, crucial para optimizar la operación y la integración de las fuentes renovables en la red eléctrica. Ver figura 9.

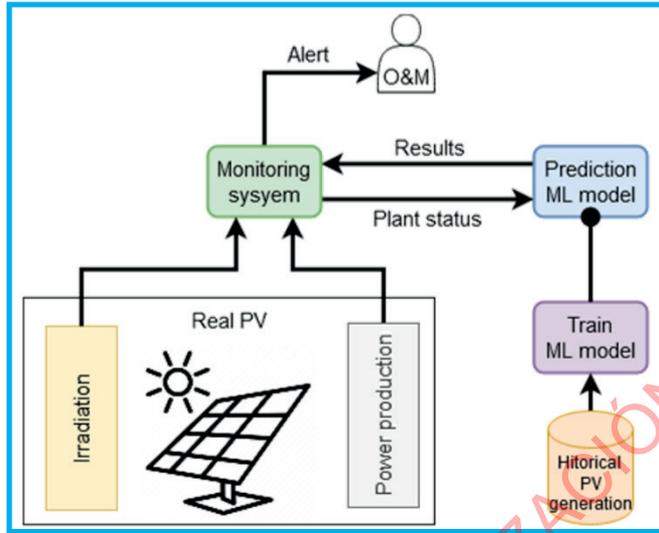


Figura 9. Sistema de predicción (Yonce *et al.*, 2023)

El proyecto comenzó con la creación de un modelo detallado de una planta fotovoltaica, denominado gemelo digital. Este modelo no solo replicaba las características físicas y operativas de la planta, sino que también incorporaba datos en tiempo real y pronósticos meteorológicos para simular su comportamiento bajo diversas condiciones ambientales. La capacidad de este modelo para reflejar la planta real permitía una simulación precisa y una predicción eficaz de la producción energética.

Para llevar a cabo las predicciones, Yonce, Walters y Venayagamoorthy utilizaron técnicas avanzadas de aprendizaje automático. Implementaron algoritmos de redes neuronales y máquinas de vector de soporte que se entrenaban con datos históricos y en tiempo real para prever la generación de energía en intervalos cortos. La precisión de estas predicciones fue esencial para gestionar la variabilidad de la energía solar y para facilitar su integración en la red eléctrica, garantizando así un suministro energético más estable y confiable.

El sistema fue probado exhaustivamente, demostrando una capacidad notable para anticipar las fluctuaciones en la producción de energía con un alto grado de precisión. Esta herramienta no solo mejoró la planificación y operación de las instalaciones fotovoltaicas, sino que también proporcionó a los operadores de la red la información necesaria para ajustar la carga y las reservas de energía de manera más eficiente.

La implementación de este gemelo digital marcó un avance significativo en la gestión de energías renovables, optimizando el rendimiento de las plantas fotovoltaicas y reforzando la fiabilidad de la red eléctrica. Este enfoque se alineó con los esfuerzos globales para aumentar la adopción de fuentes de energía renovables y minimizar la dependencia de combustibles fósiles, contribuyendo significativamente a la sostenibilidad energética y la reducción de la huella de carbono (Yonce *et al.*, 2023).

Caso 3: Reducción de Costos con Reconfiguración Offline en China

En 2020, un equipo compuesto por Wu, Zhang, Alkahtani, Hu y Zhang llevó a cabo un estudio innovador sobre la optimización de arreglos fotovoltaicos que experimentaban envejecimiento no uniforme, utilizando técnicas de IA. Publicado en *IEEE Access*, su trabajo se centró en desarrollar un sistema de reconfiguración fuera de línea que mejorara de manera costo-efectiva la eficiencia de estos arreglos a gran escala. Ver figura 10.

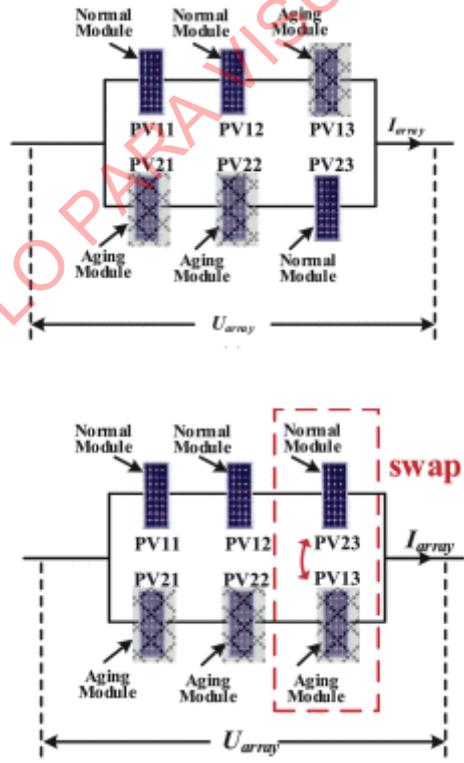


Figura 10. Arreglo fotovoltaico (Wu *et al.*, 2020)

El equipo empezó analizando extensos conjuntos de datos que incluían mediciones del rendimiento energético y las condiciones de degradación de los paneles. Estos datos alimentaron modelos de aprendizaje automático diseñados para identificar patrones y predecir la degradación futura de los paneles bajo diferentes condiciones ambientales. Las predicciones de estos modelos se utilizaron para informar las estrategias de reconfiguración del arreglo.

Los investigadores aplicaron algoritmos genéticos, una forma de IA que simula la evolución biológica, para explorar y optimizar la disposición de los paneles solares. Estos algoritmos evaluaron múltiples configuraciones potenciales, seleccionando aquellas que maximizaban la producción de energía mientras minimizaban los costos. Además, utilizaron redes neuronales para evaluar y validar la viabilidad y eficiencia de las configuraciones propuestas por los algoritmos genéticos.

Una vez desarrollado, el sistema de reconfiguración fue sometido a simulaciones iterativas que demostraron su capacidad para mejorar significativamente la eficiencia energética del sistema fotovoltaico. Este proceso no solo optimizó la producción energética, sino que también redujo la necesidad de intervenciones de mantenimiento costosas y el reemplazo prematuro de componentes.

El impacto de este enfoque fue considerable. Permitió a los operadores de plantas fotovoltaicas manejar de manera más eficiente los arreglos solares, extendiendo su vida útil y reduciendo los costos operativos. Además, al mantener los sistemas fotovoltaicos funcionando de manera eficiente por más tiempo, el proyecto contribuyó a la sostenibilidad ambiental y cumplió con los objetivos de energía renovable. Este estudio fue un ejemplo destacado de cómo la tecnología de IA puede ser aplicada para resolver problemas complejos en la gestión de energías renovables, marcando un avance significativo en la optimización de recursos y la eficiencia energética (Wu *et al.*, 2020).

Caso 4: Predicción y Optimización de la Producción con Redes Neuronales en China

En 2017, Khan, Zhu, Khan, y Panjwani presentaron un estudio innovador en la Conferencia Internacional sobre Tecnologías de Información y Comunicación (ICICT), en el que exploraron la aplicación de redes neuronales artificiales en la predicción de la producción de energía fotovoltaica. El equipo se

centró en el desarrollo y la implementación de una red neuronal artificial de tipo *cascade forward* para prever con precisión la cantidad de energía que generarían los sistemas fotovoltaicos bajo diversas condiciones ambientales.

Los investigadores comenzaron su trabajo identificando las principales variables que influyen en la producción de energía de los paneles fotovoltaicos, como la irradiación solar, la temperatura ambiental y la humedad. Utilizando estos datos como entradas, desarrollaron un modelo de red neuronal de tipo *cascade forward*. Este tipo de red se caracteriza por tener conexiones adicionales de las entradas a cada capa sucesiva, además de las conexiones estándar entre capas consecutivas, lo que potencialmente mejora la capacidad del modelo para aprender patrones complejos en los datos más rápidamente. Ver figura 11.

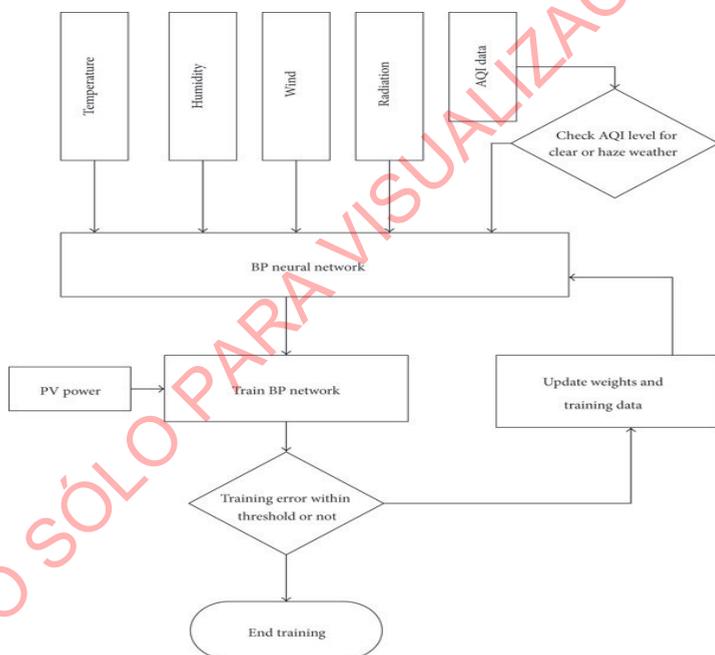


Figura 11. Diagrama de flujo del modelo (Khan *et al.*, 2017)

Para entrenar su modelo, Khan y su equipo utilizaron un vasto conjunto de datos históricos que incluía las mediciones de las variables mencionadas, junto con los registros de producción energética de los paneles fotovoltaicos. El modelo fue entrenado para aprender la relación entre las condiciones ambientales y la producción energética, optimizando sus pesos y sesgos a través de un proceso iterativo de retro propagación.

Una vez entrenado, el modelo fue sometido a pruebas rigurosas para evaluar su precisión en la predicción de la producción energética bajo nuevas condiciones ambientales. Los resultados demostraron que la red neuronal de tipo *cascade forward* proporcionaba predicciones altamente precisas, superando a otros modelos de red neuronal en términos de rapidez y precisión de aprendizaje. Esta eficacia se tradujo en una herramienta valiosa para los operadores de instalaciones fotovoltaicas, permitiéndoles anticipar y ajustar su producción basándose en las predicciones de energía.

El éxito del modelo ofreció numerosas posibilidades para su aplicación en la gestión y planificación de la producción energética en instalaciones fotovoltaicas. Al prever con precisión la cantidad de energía que se generará, los operadores pueden optimizar la operación de sus instalaciones y mejorar la integración de la energía solar en la red eléctrica general. Además, los resultados del estudio sugirieron que modelos similares podrían ser efectivos en otras aplicaciones dentro de las energías renovables, como la predicción de la producción eólica.

El trabajo de Khan y su equipo marcó un avance significativo en el uso de redes neuronales avanzadas para la predicción de la producción energética, destacando el potencial de la IA para mejorar la eficiencia y la efectividad de las tecnologías de energía renovable (Khan *et al.*, 2017).

4.2. Aplicación de la Inteligencia Artificial en energía eólica

En esta sección, se presentan casos de estudio detallados de proyectos reales donde se ha aplicado la IA en sistemas de energía eólica para mejorar su rendimiento, eficiencia y rentabilidad.

Caso 1: Maximización de la Energía Generada con Control de Ángulo de Pala en Etiopía

En 2022, Ayenew y Berhanu exploraron cómo las técnicas de IA podían ser aplicadas para maximizar la capacidad de generación de energía de las turbinas eólicas. Su investigación, publicada en la revista *Energy Sources Part A: Recovery, Utilization, and Environmental Effects*, proporcionó un análisis detallado y una metodología innovadora para mejorar la eficiencia de las turbinas eólicas mediante el uso de avanzados algoritmos de IA.

Aynew y Berhanu comenzaron su estudio identificando las variables críticas que afectan el rendimiento de las turbinas eólicas, como la velocidad del viento, la densidad del aire, y la temperatura. Basándose en estas variables desarrollaron un modelo de IA para predecir y optimizar la producción de energía de las turbinas. Utilizaron algoritmos de aprendizaje automático, especialmente técnicas de aprendizaje profundo, para crear un modelo predictivo capaz de ajustar dinámicamente las operaciones de las turbinas en respuesta a las condiciones ambientales cambiantes. Ver figura 12.

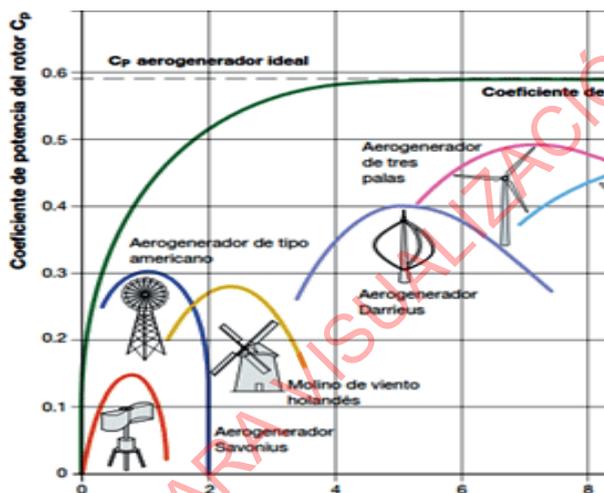


Figura 12. Límite de Betz's (Aynew & Berhanu, 2022)

Los investigadores emplearon redes neuronales profundas debido a su capacidad para manejar grandes volúmenes de datos y aprender patrones complejos. Estas redes fueron entrenadas con datos históricos de rendimiento de turbinas eólicas, incluyendo variables meteorológicas y operativas. El entrenamiento permitió al modelo aprender las relaciones entre las condiciones del viento y la eficiencia de la generación de energía, optimizando así las configuraciones de las turbinas para maximizar su salida.

Una vez desarrollado el modelo de IA, Aynew y Berhanu procedieron a validar su eficacia mediante pruebas en diversas condiciones operativas y comparaciones con modelos de control estándar. Los resultados demostraron que su modelo de IA podía prever con precisión la producción energética óptima y ajustar las operaciones de las turbinas en tiempo real para aprovechar al

máximo las condiciones del viento. Este ajuste dinámico resultó en un aumento significativo en la eficiencia y la producción de energía en comparación con las turbinas que no utilizaban su sistema de IA.

La investigación de Ayenew y Berhanu destacó el potencial de la IA para revolucionar la industria eólica. Al maximizar la eficiencia de las turbinas eólicas, su metodología no solo prometía reducir los costos operativos, sino también aumentar la viabilidad de los proyectos de energía eólica al mejorar su rentabilidad. Además, el estudio sugirió que técnicas similares podrían ser aplicadas a otras formas de energía renovable, abriendo nuevas vías para la optimización y la automatización en el sector energético.

Este trabajo sirvió como un ejemplo valioso de cómo la integración de técnicas de IA en la gestión de energías renovables puede proporcionar beneficios significativos en términos de eficiencia operativa y sostenibilidad ambiental, señalando un camino hacia un futuro energético más inteligente y verde (Ayenew & Berhanu, 2022).

Caso 2: Monitoreo y Diagnóstico de Fallos con IA en Japón

En 2019, B. K. Bose examinó en profundidad las aplicaciones de la IA en sistemas de energía renovable y redes inteligentes en su capítulo del libro *Power Electronics in Renewable Energy Systems and Smart Grid*. Este análisis destacó una serie de aplicaciones novedosas de la IA que prometían transformar y mejorar significativamente la eficiencia, fiabilidad y sostenibilidad de las energías renovables y las infraestructuras de red. Ver figura 13.

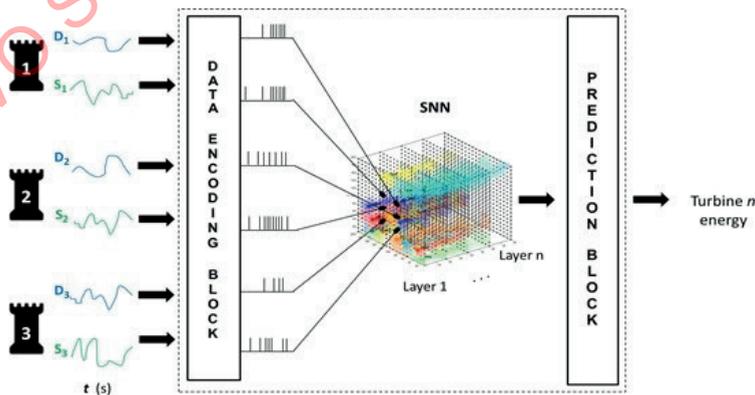


Figura 13. Red neuronal (Bose, 2019).

Bose abordó cómo la IA había sido utilizada para optimizar la producción de energía en sistemas como los solares y eólicos. Describió el uso de sistemas de predicción basados en redes neuronales y algoritmos de aprendizaje automático que predecían la producción energética en función de las condiciones meteorológicas y ambientales. Estos modelos permitían a los operadores ajustar las operaciones de manera proactiva para maximizar la eficiencia.

El capítulo también profundizó en la aplicación de la IA en la gestión de redes inteligentes. Bose ilustró cómo técnicas de aprendizaje profundo y el procesamiento de grandes volúmenes de datos podían ayudar a anticipar y manejar la demanda y oferta de energía de forma más efectiva. Esto incluía la optimización de flujos de energía en tiempo real y la implementación de sistemas de respuesta a la demanda que ajustaban automáticamente el consumo de energía en hogares y empresas basándose en la disponibilidad de energía renovable.

Además, se exploró el uso de la IA para el mantenimiento predictivo de infraestructuras de energía renovable. Mediante algoritmos de aprendizaje automático, se podían analizar datos de operación en tiempo real para detectar patrones que indicaran un potencial fallo o degradación de los equipos. Esto posibilitaba realizar intervenciones de mantenimiento antes de que ocurrieran averías, reduciendo los tiempos de inactividad y aumentando la vida útil de los equipos.

Concluyó evaluando el impacto transformador de la IA en el sector energético y discutiendo futuras direcciones de investigación. Bose enfatizó la importancia de desarrollar soluciones de IA más sofisticadas que pudieran integrarse efectivamente en el diseño y operación de sistemas de energía renovable y redes inteligentes, fomentando una transición hacia un sistema energético más sostenible y eficiente.

El trabajo de Bose proporcionó una visión comprensiva de cómo la integración de la IA en el campo de las energías renovables y las redes inteligentes podría conducir a avances significativos en términos de operación, mantenimiento y eficiencia energética, marcando un camino prometedor para futuras innovaciones en el sector (Bose, 2019).

4.3. Aplicación de la Inteligencia Artificial en energía hidroeléctrica

En esta sección, se presentan casos de estudio detallados de proyectos reales donde se ha aplicado la IA en sistemas de energía hidroeléctrica para mejorar su rendimiento, eficiencia y sostenibilidad.

Caso 1: *Mantenimiento Predictivo en la Planta Hidroeléctrica de Peña Blanca*

En 2022, Velásquez y Flores presentaron un estudio en el Congreso Bianual de la IEEE en Argentina (ARGENCON), en el cual exploraron el uso de técnicas de aprendizaje automático para el mantenimiento predictivo en plantas hidroeléctricas. Su investigación se centró en desarrollar y aplicar modelos de aprendizaje automático que podrían prever y prevenir fallas en los componentes críticos de las plantas, con el objetivo de mejorar la eficiencia y reducir los costos de mantenimiento. Ver figura 14.



Figura 14. turbina hidroeléctrica (Velasquez & Flores, 2022)

Velasquez y Flores comenzaron su proyecto identificando los datos operativos clave que se recopilaban regularmente en las plantas hidroeléctricas, como las vibraciones de las turbinas, temperaturas, presiones y flujos de agua.

Estos datos fueron utilizados para entrenar modelos de aprendizaje automático capaces de detectar patrones y anomalías que indicaran posibles fallos antes de que ocurrieran.

Los investigadores eligieron modelos de aprendizaje automático supervisado debido a su capacidad para aprender de datos etiquetados, en este caso, datos históricos de funcionamiento de la planta junto con registros de incidentes y fallas pasadas. Se utilizó una combinación de técnicas, incluyendo árboles de decisión y redes neuronales, para desarrollar un sistema robusto que pudiera adaptarse a las condiciones cambiantes de operación y a la variabilidad natural de los datos de la planta.

Una vez desarrollado el modelo, Velasquez y Flores realizaron una serie de pruebas para validar su precisión y eficacia. El modelo demostró ser capaz de identificar con éxito los signos de deterioro y otros indicadores de problemas inminentes, permitiendo así intervenciones de mantenimiento proactivas que ayudaban a evitar paradas no programadas y otros problemas operativos costosos.

La aplicación de estos modelos de aprendizaje automático en el mantenimiento predictivo transformó la forma en que se realizaba el mantenimiento en las plantas hidroeléctricas. Al predecir fallos antes de que ocurrieran, las plantas podían programar el mantenimiento durante períodos de baja demanda, minimizando el impacto en la producción y maximizando la eficiencia operativa. Además, el estudio de Velasquez y Flores destacó el potencial de expansión de estas técnicas a otras áreas de la industria energética, donde el mantenimiento predictivo podría generar ahorros significativos y mejorar la fiabilidad de las operaciones.

Este trabajo no solo reforzó la viabilidad de aplicar técnicas de aprendizaje automático en entornos industriales complejos, sino que también ofreció un camino prometedor hacia la optimización de la gestión de activos y la operación de plantas de energía renovable (Velasquez & Flores, 2022).

Caso 2: Optimización de la Generación en la Planta Hidroeléctrica de Bhakra-Nangal

En 2021, Kumar y Saini investigaron la aplicación de técnicas de IA para optimizar la generación de energía hidroeléctrica. Su estudio, publicado en las *EAI Endorsed Transactions on Industrial Networks and Intelligent Systems*, se centró

en cómo los modelos de IA podrían mejorar la eficiencia y la productividad de las plantas hidroeléctricas, así como la gestión de sus recursos hídricos.

Kumar y Saini comenzaron identificando las variables operativas y ambientales clave que influyen en la generación de energía hidroeléctrica, tales como el caudal del agua, las precipitaciones, la temperatura, y los niveles de los embalses. Estos datos se utilizaron para entrenar modelos de IA que pudieran predecir la disponibilidad de recursos hídricos y optimizar su uso para la generación de energía. Ver figura 15.



Figura 15. Planta Hidroeléctrica (Kumar & Saini, 2021)

Los investigadores emplearon una variedad de técnicas de aprendizaje automático, incluyendo redes neuronales y algoritmos de optimización, para desarrollar un sistema capaz de ajustar las operaciones de la planta en tiempo real. El objetivo era maximizar la eficiencia de la generación de energía mientras se minimizaban los impactos ambientales negativos, como el desbordamiento de embalses o la escasez de agua durante períodos de sequía.

Una vez desarrollado, el modelo fue probado en diferentes escenarios hidrológicos y operativos para evaluar su precisión y robustez. Los resultados demostraron que el modelo de IA podía prever de manera efectiva las condiciones futuras del agua y ajustar las operaciones de la planta para optimizar tanto la generación de energía como la conservación de recursos hídricos.

El estudio de Kumar y Saini mostró que la aplicación de IA en la gestión de plantas hidroeléctricas podría significar un gran avance en la eficiencia y

sostenibilidad de estas instalaciones. Al prever y adaptarse a las condiciones cambiantes, las plantas no solo podrían generar energía más eficientemente, sino también manejar de manera más efectiva los recursos hídricos en un clima cada vez más impredecible.

Este trabajo subrayó la importancia y el potencial de integrar técnicas avanzadas de IA en el sector energético, no solo para mejorar la eficiencia operativa, sino también para contribuir a la gestión ambiental y la sostenibilidad a largo plazo (Kumar & Saini, 2021).

Caso 3: Diseño y Simulación de Sistemas Hidroeléctricos en la Planta de Three Gorges

En 1992, Smithers y Tang exploraron la aplicación de la IA en el diseño y la simulación de sistemas hidroeléctricos. Publicaron sus hallazgos en los *IFAC Proceedings Volumes*, proporcionando una visión innovadora sobre cómo las técnicas de IA podrían ser utilizadas para mejorar el desarrollo de infraestructuras de energía hidroeléctrica. Su trabajo se concentró en crear modelos de simulación asistidos por IA que facilitarían la planificación y optimización de estos complejos sistemas energéticos.

Smithers y Tang comenzaron su proyecto desarrollando modelos de simulación que integraban técnicas avanzadas de IA para modelar el comportamiento y las operaciones de las plantas hidroeléctricas. Ver figura 16.

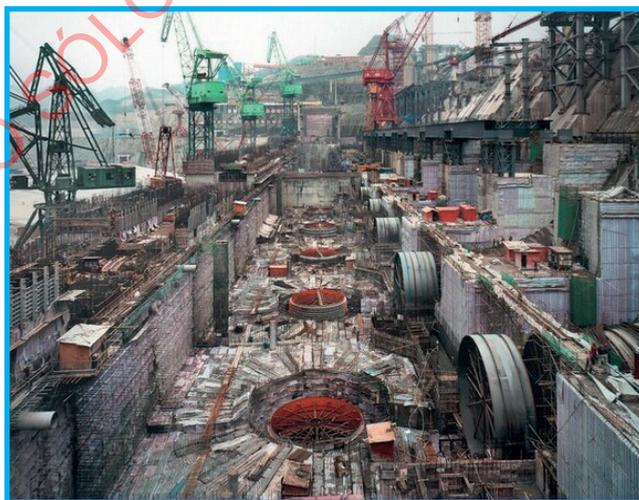


Figura 16. Construcción de hidro eléctrica Tres Gargantas China (Smithers & Tang, 1992).

Estos modelos buscaban replicar las condiciones dinámicas y las decisiones operativas dentro de un entorno controlado, permitiendo a los ingenieros y diseñadores prever el rendimiento de las instalaciones antes de su construcción o modificación.

Los investigadores emplearon varios métodos de IA, incluyendo lógica difusa y sistemas expertos, para manejar la incertidumbre y la complejidad inherentes a la gestión del agua y la generación de energía. Estas técnicas permitieron simular diversas situaciones operativas y ambientales, proporcionando datos valiosos sobre cómo variaciones específicas podrían impactar la eficiencia y la seguridad de las plantas hidroeléctricas.

Los modelos de simulación desarrollados por Smithers y Tang fueron sometidos a pruebas exhaustivas para validar su precisión y utilidad. Los resultados mostraron que estos modelos no solo eran capaces de simular con precisión el funcionamiento de las plantas hidroeléctricas, sino que también ofrecían recomendaciones prácticas para su optimización. Estas simulaciones ayudaron a identificar oportunidades de mejora en el diseño y operación de las instalaciones, reduciendo potencialmente los costos y aumentando la producción de energía.

El estudio de Smithers y Tang marcó un avance importante en el uso de la IA para el diseño de infraestructuras energéticas. Al demostrar que los modelos de simulación basados en IA pueden mejorar significativamente la planificación y ejecución de proyectos hidroeléctricos, abrieron el camino para futuras investigaciones y aplicaciones en el campo. Su trabajo anticipó el creciente rol de la tecnología de IA en la ingeniería y gestión de sistemas energéticos, sugiriendo un futuro donde las decisiones de diseño y operativas podrían ser considerablemente más informadas y efectivas (Smithers & Tang, 1992).

4.4. Aplicación de la Inteligencia Artificial en energía geotérmica

En esta sección, se presentan casos de estudio detallados de proyectos reales donde se ha aplicado la IA en sistemas de energía geotérmica para mejorar su exploración, explotación y mantenimiento.

Caso 1: Optimización de caudales de pozos

En 2019, M. S. Ariturk presentó una investigación innovadora como parte de su trabajo en la West Virginia University, enfocada en optimizar los caudales de los pozos de producción e inyección en campos geotérmicos mediante el uso de IA. Este estudio destacó el potencial de la IA para mejorar la eficiencia y la gestión de los recursos geotérmicos, un área crítica en la expansión de las energías renovables. Ver figura 17.



Figura 17. Campo Geotérmico de Kizildere, Turquía (Ariturk, 2019)

Ariturk inició su investigación identificando las variables clave que influyen en el rendimiento de los pozos geotérmicos, tales como las características geológicas del subsuelo, la temperatura, y la presión del agua subterránea. Utilizando estos datos, desarrolló modelos de IA que podían prever y optimizar los caudales de los pozos de manera que maximizaran la extracción de energía mientras se minimizaban los impactos ambientales y el agotamiento de los recursos.

El enfoque de Ariturk incluyó el uso de algoritmos de aprendizaje automático para analizar grandes cantidades de datos operativos y ambientales de los campos geotérmicos. Estos algoritmos, como las redes neuronales y las máquinas de soporte vectorial, fueron entrenados para identificar patrones y correlaciones que podrían no ser evidentes mediante métodos analíticos

tradicionales. El modelo de IA estaba diseñado para ajustar de manera continua los caudales de los pozos en respuesta a las condiciones cambiantes del subsuelo y las demandas de producción.

Una vez desarrollado, el modelo de IA fue sometido a pruebas rigurosas para asegurar su precisión y eficacia. Ariturk validó su modelo mediante la simulación de diferentes escenarios operativos en el campo geotérmico. Los resultados demostraron que la IA podía predecir con precisión los rendimientos óptimos de los pozos y ajustar sus operaciones en tiempo real para lograr una gestión eficiente del recurso geotérmico.

El trabajo de Ariturk proporcionó una herramienta valiosa para los operadores de campos geotérmicos, permitiendo una gestión más precisa y dinámica de los pozos de producción e inyección. Esta optimización llevó a una mejora significativa en la eficiencia energética y la sostenibilidad de las operaciones geotérmicas. Además, el estudio señaló el potencial de aplicar técnicas similares de IA en otros aspectos de la exploración y explotación de energías renovables, ofreciendo perspectivas para futuras investigaciones y desarrollos tecnológicos en el sector.

El enfoque de Ariturk resaltó cómo la IA puede transformar la industria geotérmica, optimizando operaciones y promoviendo el uso eficiente de los recursos naturales, allanando el camino para un futuro más sostenible en la producción de energía renovable (Ariturk, 2019).

Caso 2: Optimización Operativa en Plantas Geotérmicas con Gemelos Digitales en Nueva Zelanda.

En 2021, Buster, Siratovich, Taverna, Rossol, Weers, Blair, Huggins, Siega, Mannington, Urgel, Cen, Quinao, Watt, y Akerley; colaboraron en un estudio innovador que introdujo un nuevo marco de modelado para la optimización operativa geotérmica mediante el uso de aprendizaje automático, denominado Geothermal Operational Optimization with Machine Learning (GOOML). Publicado en la revista *Energies*, este marco representó un paso adelante en la aplicación de tecnologías avanzadas para mejorar la eficiencia y efectividad de las operaciones en campos geotérmicos. Ver figura 18.

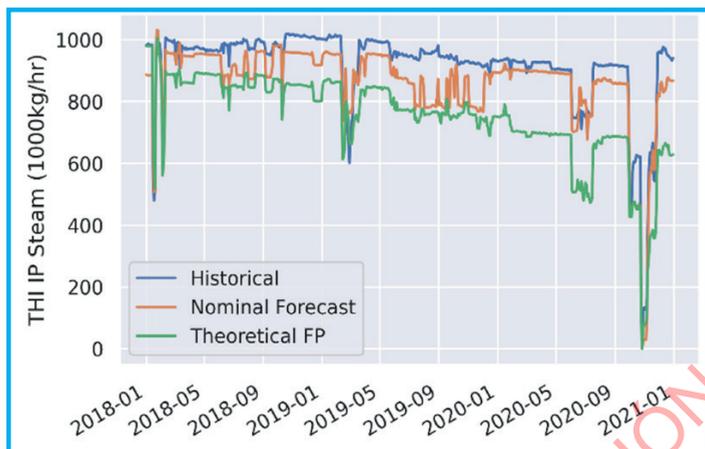


Figura 18. Predicción de rendimiento geotérmico (Buster *et al.*, 2021)

El equipo multidisciplinario desarrolló GOOML con el objetivo de integrar diversas fuentes de datos y técnicas de aprendizaje automático para optimizar la gestión de los recursos geotérmicos. Este marco incorporó datos desde mediciones en tiempo real hasta historiales de producción y variables geológicas, todo procesado a través de modelos de aprendizaje automático para mejorar las decisiones operativas.

GOOML utilizó un conjunto diverso de técnicas de aprendizaje automático, incluyendo redes neuronales, árboles de decisión y algoritmos de ensamblaje, para analizar y predecir los comportamientos de los pozos geotérmicos. Estos modelos fueron diseñados para identificar patrones y prever posibles problemas antes de que afectaran la producción, optimizando tanto la extracción de calor como la reinserción de fluidos en el subsuelo.

Una vez implementado, GOOML fue sometido a pruebas exhaustivas para verificar su eficacia. Los resultados demostraron que el marco no solo era capaz de mejorar significativamente la eficiencia operativa, sino también de aumentar la sostenibilidad de las operaciones geotérmicas al minimizar el impacto ambiental y mejorar la gestión de los recursos. Las pruebas incluyeron simulaciones detalladas que replicaron diversas condiciones operativas y desafíos comunes en la industria geotérmica.

El trabajo de este equipo internacional proporcionó una nueva herramienta para la industria geotérmica, permitiendo una optimización más precisa y fundamentada de las operaciones. La aplicación de GOOML prometía no

solo incrementar la producción de energía geotérmica, sino también prolongar la vida útil de los recursos geotérmicos. Además, este marco abrió la puerta a futuras investigaciones y desarrollos en el uso de IA para otras formas de energía renovable, destacando la importancia de la tecnología en la transición hacia fuentes de energía más sostenibles.

Este estudio fue un ejemplo clave de cómo la colaboración interdisciplinaria y el uso innovador de tecnologías de IA pueden llevar a mejoras significativas en la eficiencia y sostenibilidad de las operaciones energéticas, marcando un avance significativo en la optimización de los recursos naturales y la producción de energía (Buster *et al.*, 2021).

4.5. Aplicación de la Inteligencia Artificial en energía de biomasa

En esta sección, se presentan casos de estudio detallados de proyectos reales donde se ha aplicado la IA en sistemas de energía de biomasa para mejorar su eficiencia, sostenibilidad y rentabilidad.

Caso 1: Modelado Dinámico de Plantas de Biomasa con Microturbinas de Gas en la Universidad de Pisa

En 2015, Barsali, De Marco, Giglioli, Ludovici, y Possenti publicaron un estudio en la revista *Renewable Energy* sobre la modelización dinámica de una planta de energía de biomasa utilizando una microturbina de gas. Este trabajo proporcionó una visión detallada del potencial de las microturbinas de gas para mejorar la eficiencia y la flexibilidad de las plantas de energía de biomasa. Ver figura 19.

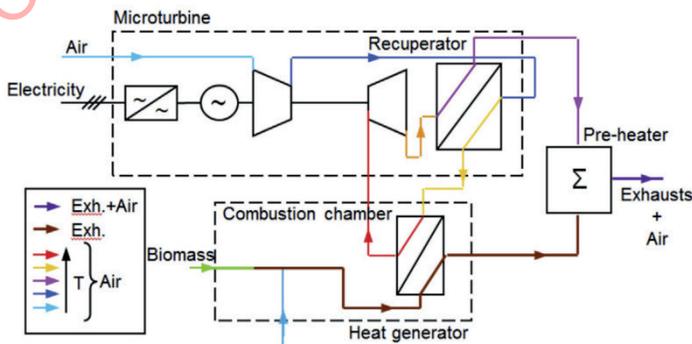


Figura 19. Diseño de microturbina de 70kW (Barsali *et al.*, 2015)

El equipo comenzó su proyecto desarrollando un modelo dinámico que simulaba el comportamiento de una planta de biomasa equipada con una microturbina de gas. Este modelo estaba diseñado para capturar la compleja interacción entre los diversos componentes del sistema, incluyendo el proceso de gasificación de la biomasa, la generación de energía, y el manejo de emisiones.

El modelo dinámico incorporó varios submodelos que representaban los diferentes procesos y operaciones dentro de la planta. Se prestó especial atención al diseño del gasificador y a la integración de la microturbina, buscando optimizar el flujo de gases y maximizar la eficiencia térmica y eléctrica. Además, se consideraron aspectos como las variaciones en la calidad de la biomasa y su impacto en el rendimiento general del sistema.

Una vez desarrollado, el modelo fue validado utilizando datos experimentales de plantas de biomasa operativas. Los resultados de las simulaciones mostraron que el modelo podía predecir con precisión el comportamiento de la planta bajo diferentes condiciones operativas y tipos de biomasa. Esto permitió a los investigadores evaluar diferentes estrategias para mejorar la eficiencia y adaptabilidad de la planta.

El estudio de Barsali y su equipo demostró que la integración de microturbinas de gas en plantas de biomasa podría ofrecer una mejora significativa en la eficiencia energética y la reducción de emisiones. Este enfoque permitía una mayor flexibilidad operativa, especialmente útil en aplicaciones donde la demanda de energía fluctúa o donde la biomasa disponible varía en calidad.

El trabajo también sugirió que el modelo podría ser utilizado para el diseño y la optimización de nuevas instalaciones de energía de biomasa, así como para la modernización de plantas existentes. Esta investigación proporcionó una base sólida para futuros desarrollos en el campo de la energía de biomasa, destacando cómo la modelización avanzada y la integración de nuevas tecnologías pueden conducir a sistemas de energía renovable más eficientes y sostenibles (Barsali *et al.*, 2015).

Caso 2: Modelo de Optimización Térmico-Económica en Alemania

En 2014, Nusiaputra, Wiemer y Kuhn llevaron a cabo un estudio innovador sobre la modularización térmico-económica de pequeñas plantas de energía que emplean el Ciclo Orgánico de Rankine (ORC) para campos geotérmicos de entalpía media. Este trabajo, publicado en la revista *Energies*, ofreció una visión

avanzada para optimizar el uso de recursos geotérmicos menos intensivos a través de un enfoque modular. Ver figura 20.

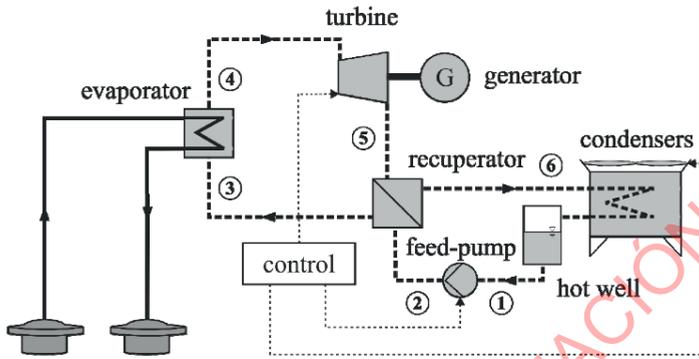


Figura 20. Planta de ciclo Rankine orgánico (Nusiaputra *et al.*, 2014).

El equipo propuso un sistema modular para plantas ORC que permitía una escalabilidad y una adaptación óptimas a las condiciones específicas de cada campo geotérmico. Este enfoque buscaba abordar el problema de la viabilidad económica de explotar recursos geotérmicos de entalpía media, comúnmente no utilizados debido a las limitaciones tecnológicas y económicas de los sistemas más grandes y tradicionales.

El diseño de los módulos ORC se centró en maximizar la eficiencia de la conversión de calor geotérmico en electricidad. Cada módulo era capaz de operar de manera independiente o en conjunto con otros módulos, permitiendo una configuración flexible que se podía ajustar según las variaciones en la disponibilidad del recurso geotérmico y las demandas de energía.

Una parte crucial de su investigación fue la evaluación térmico-económica para determinar la eficiencia y coste-efectividad de la implementación modular. Utilizaron análisis detallados para comparar los costos de inversión y operativos con el rendimiento energético esperado, demostrando que los módulos ORC podían ofrecer una mejor relación costo-beneficio comparado con las soluciones más convencionales.

El concepto de modularización fue evaluado mediante modelos computacionales y pruebas piloto en locaciones seleccionadas. Estas pruebas validaron la capacidad del modelo para adaptarse a diferentes escenarios

operativos y mostraron cómo la modularización podía mejorar significativamente la eficiencia operativa y la sostenibilidad de las plantas de energía geotérmica.

El estudio reveló que el enfoque modular no solo facilita una explotación más eficiente de los campos geotérmicos de entalpía media, sino que también reduce significativamente los riesgos financieros asociados con la inversión en energía geotérmica. Además, propuso un camino para la expansión futura de esta tecnología a otras formas de energía renovable, sugiriendo que la modularización podría adaptarse a diferentes contextos y necesidades energéticas.

La investigación de Nusiaputra, Wiemer y Kuhn marcó un hito importante en la utilización de recursos geotérmicos subutilizados y estableció un fundamento sólido para el desarrollo continuo de tecnologías ORC más eficientes y accesibles, promoviendo una mayor adopción de soluciones de energía renovable sostenibles y económicamente viables (Nusiaputra *et al.*, 2014).

Caso 3: Simulación y Optimización del Sistema de Energía Híbrido en Argelia

En 2018, Tabanjat, Becherif, Hissel y Ramadan publicaron un estudio en el *International Journal of Hydrogen Energy* explorando la gestión de energía en sistemas de energía híbridos que integran hidrógeno, turbinas eólicas, paneles fotovoltaicos y microturbinas de gas a través de técnicas de IA. Este enfoque innovador tenía como objetivo optimizar la eficiencia y la fiabilidad de estos sistemas híbridos, mejorando la integración y gestión de diversas fuentes de energía renovable y convencional. Ver figura 21.

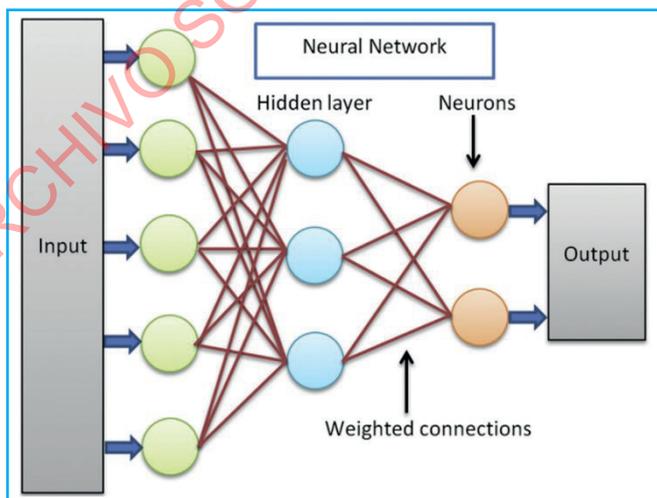


Figura 21. Red neuronal del sistema híbrido (Tabanjat *et al.*, 2017).

El equipo comenzó su proyecto desarrollando un modelo de gestión de energía que utilizaba técnicas avanzadas de IA para coordinar la operación de las cuatro tecnologías de generación de energía. Este sistema estaba diseñado para manejar la variabilidad en la producción de energía de las fuentes renovables y para asegurar un suministro de energía constante y eficiente.

Las técnicas de IA implementadas incluían algoritmos de aprendizaje automático y sistemas de control basados en lógica difusa. Estos sistemas eran capaces de predecir la producción de energía de las fuentes renovables y ajustar de manera proactiva la operación de las microturbinas de gas y los sistemas de almacenamiento de hidrógeno para compensar cualquier déficit o exceso de producción.

El modelo de gestión de energía fue evaluado mediante simulaciones que replicaban diversas condiciones ambientales y patrones de demanda energética. Las pruebas demostraron que el sistema híbrido gestionado por IA podía mejorar significativamente la estabilidad y la eficiencia del suministro de energía, reduciendo la dependencia de fuentes de energía no renovables y optimizando el uso de energía renovable.

El estudio de Tabanjat y su equipo mostró que los sistemas de gestión de energía basados en IA pueden ser cruciales para la integración efectiva de múltiples fuentes de energía en un solo sistema híbrido. Esta investigación abrió nuevas vías para el diseño de sistemas de energía más robustos y eficientes que pueden adaptarse dinámicamente a cambios en la producción de energía y en la demanda.

Además, el modelo propuesto ofreció una solución prometedora para mejorar la sostenibilidad y eficiencia de los sistemas de energía a gran escala, sugiriendo que técnicas similares podrían aplicarse en otros contextos que requieren la integración de diversas fuentes de energía renovable y la gestión eficiente del almacenamiento y conversión de energía.

Este trabajo no solo proporcionó una base técnica para futuras investigaciones en la gestión de sistemas de energía híbridos, sino que también destacó la importancia de la IA como una herramienta poderosa para resolver complejos desafíos energéticos en un mundo cada vez más enfocado en la sostenibilidad (Tabanjat *et al.*, 2018).

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Parte V

Desafíos y Consideraciones Éticas

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Capítulo 5

Desafíos y Consideraciones Éticas

La aplicación de la IA en el ámbito de las energías renovables presenta un enorme potencial para optimizar y potenciar el rendimiento de los sistemas de energía solar, eólica, hidroeléctrica, geotérmica y de biomasa, como se ha demostrado en los capítulos anteriores. Sin embargo, la convergencia entre la IA y las energías renovables también plantea diversos desafíos técnicos, económicos y éticos que deben abordarse para garantizar un desarrollo y uso responsable, transparente y beneficioso de estas tecnologías (Agarwal *et al.*, 2020).

Uno de los principales obstáculos técnicos y económicos para la adopción generalizada de la IA en las energías renovables es la disponibilidad y calidad de los datos necesarios para entrenar y aplicar los algoritmos. Según Hannan *et al.* (2021):

la falta de datos históricos suficientes, precisos y representativos sobre el rendimiento de los sistemas de energía renovable, las condiciones ambientales y las variables operativas puede limitar la capacidad de los modelos de IA para aprender patrones y relaciones significativas y generalizables. (p. 14)

Además, la heterogeneidad, la dispersión y la falta de estandarización de los datos provenientes de diferentes fuentes y sistemas pueden dificultar su integración y análisis efectivo mediante técnicas de IA (Agarwal *et al.*, 2020).

Otro desafío técnico es la complejidad y la incertidumbre inherentes a los sistemas de energía renovable, que pueden afectar la precisión y la confiabilidad de los modelos de IA. Según Hannan *et al.* (2021):

los sistemas de energía renovable están sujetos a múltiples fuentes de incertidumbre, como la variabilidad climática, la intermitencia de los recursos renovables, las dinámicas no lineales de los componentes y las interacciones complejas entre los subsistemas, que pueden ser difíciles de capturar y predecir mediante enfoques de IA. (p. 14)

Además, la falta de interpretabilidad y transparencia de algunos modelos de IA, especialmente los basados en aprendizaje profundo, puede limitar su

aceptación y confianza por parte de los operadores y responsables de la toma de decisiones en el sector energético (Hannan *et al.*, 2021).

Desde una perspectiva económica, el costo y la rentabilidad de las soluciones basadas en IA para las energías renovables pueden ser un obstáculo para su adopción. Según Agarwal *et al.* (2020):

el desarrollo, la implementación y el mantenimiento de los sistemas de IA requieren inversiones significativas en infraestructura de TI, personal especializado y capacitación, que pueden ser difíciles de justificar para las empresas de energía renovable, especialmente en un contexto de márgenes ajustados y presupuestos limitados. (p. 9)

Además, la falta de estudios de caso y análisis de costo-beneficio concretos que demuestren el valor y el retorno de la inversión de las aplicaciones de IA en energías renovables puede obstaculizar su adopción por parte de las empresas y los inversores (Agarwal *et al.*, 2020).

Además de los desafíos técnicos y económicos, la aplicación de la IA en las energías renovables también plantea importantes consideraciones éticas que deben abordarse. Una de las principales preocupaciones es la privacidad y seguridad de los datos utilizados por los sistemas de IA. Según Vinuesa *et al.* (2020):

los algoritmos de IA requieren grandes cantidades de datos de usuarios, dispositivos y sistemas energéticos, que pueden incluir información sensible y personal, como patrones de consumo, ubicación y preferencias, lo que plantea riesgos de privacidad y ciberseguridad si estos datos no se recopilan, almacenan y procesan de manera adecuada. (p. 2)

Otra consideración ética es la transparencia y explicabilidad de los algoritmos y modelos de IA utilizados en los sistemas de energía renovable. Según Asilomar (2017).

la opacidad y la falta de comprensión de algunos sistemas de IA, especialmente los basados en aprendizaje profundo, pueden generar desconfianza y preocupaciones sobre la equidad, la imparcialidad y la rendición de cuentas de las decisiones y acciones tomadas por estos sistemas. (p. 3)

Es importante desarrollar y aplicar principios de transparencia y explicabilidad en el diseño y uso de los algoritmos de IA en energías renovables,

para que los operadores, reguladores y usuarios puedan entender y auditar su funcionamiento y detectar posibles sesgos o errores (Asilomar, 2017).

Además, la aplicación de la IA en energías renovables también puede tener implicaciones éticas relacionadas con el impacto en el empleo y la distribución de los beneficios. Según Ding *et al.* (2021):

la automatización y optimización de los sistemas de energía renovable mediante IA puede llevar a la pérdida de puestos de trabajo en algunas áreas, como la operación y el mantenimiento manual, lo que plantea desafíos de transición justa y equitativa para los trabajadores afectados. (p. 10)

Es necesario desarrollar políticas y estrategias para anticipar y mitigar los impactos negativos de la IA en el empleo en el sector energético, y garantizar que los beneficios económicos y sociales de estas tecnologías se distribuyan de manera justa y equitativa (Ding *et al.*, 2021).

Para abordar estos desafíos y consideraciones éticas, es fundamental establecer principios y directrices éticas para el desarrollo y uso de la IA en energías renovables, que promuevan la transparencia, la equidad, la responsabilidad y el beneficio social. Esto implica la participación de todas las partes interesadas, incluyendo la industria, la academia, el gobierno y la sociedad civil, en la discusión y definición de estos principios y en la supervisión de su implementación (Vinuesa *et al.*, 2020). Además, es necesario fomentar la investigación interdisciplinaria y la colaboración entre expertos en IA, energías renovables, ética y políticas públicas, para desarrollar soluciones integrales y sostenibles que aborden los desafíos técnicos, económicos y éticos de manera holística (Agarwal *et al.*, 2020).

Finalmente, la aplicación de la IA en las energías renovables presenta tanto oportunidades como desafíos y consideraciones éticas que deben abordarse de manera proactiva y responsable. Superar los obstáculos técnicos y económicos, garantizar la privacidad y seguridad de los datos, promover la transparencia y explicabilidad de los algoritmos, y asegurar una transición justa y equitativa para los trabajadores y las comunidades afectadas, son aspectos clave para aprovechar al máximo el potencial transformador de la IA en el sector energético renovable. Solo mediante un enfoque multidisciplinario, colaborativo y éticamente fundamentado, será posible avanzar hacia un futuro energético más inteligente, sostenible y equitativo.

5.1. Obstáculos técnicos y económicos

A pesar de los beneficios y las oportunidades que ofrece la IA para las energías renovables, su adopción y aplicación generalizada aún enfrenta diversos desafíos técnicos y económicos que deben abordarse.

Uno de los principales obstáculos técnicos es la disponibilidad y calidad de los datos necesarios para entrenar y aplicar los algoritmos de IA. Según Agarwal *et al.* (2020):

la falta de datos históricos suficientes, precisos y representativos sobre el rendimiento de los sistemas de energía renovable, las condiciones ambientales y las variables operativas puede limitar la capacidad de los modelos de IA para aprender patrones y relaciones significativas y generalizables. (p. 7)

Además, la heterogeneidad, la dispersión y la falta de estandarización de los datos provenientes de diferentes fuentes y sistemas pueden dificultar su integración y análisis efectivo mediante técnicas de IA (Agarwal *et al.*, 2020).

Otro desafío técnico es la complejidad y la incertidumbre inherentes a los sistemas de energía renovable, que pueden afectar la precisión y la confiabilidad de los modelos de IA. Según Hannan *et al.* (2021):

los sistemas de energía renovable están sujetos a múltiples fuentes de incertidumbre, como la variabilidad climática, la intermitencia de los recursos renovables, las dinámicas no lineales de los componentes y las interacciones complejas entre los subsistemas, que pueden ser difíciles de capturar y predecir mediante enfoques de IA. (p. 14)

Además, la falta de interpretabilidad y transparencia de algunos modelos de IA, especialmente los basados en aprendizaje profundo, puede limitar su aceptación y confianza por parte de los operadores y responsables de la toma de decisiones en el sector energético (Hannan *et al.*, 2021).

Desde una perspectiva económica, el costo y la rentabilidad de las soluciones basadas en IA para las energías renovables pueden ser un obstáculo para su adopción. Según Agarwal *et al.* (2020):

el desarrollo, la implementación y el mantenimiento de los sistemas de IA requieren inversiones significativas en infraestructura de TI, personal especializado y capacitación, que pueden ser difíciles de justificar para las empresas de energía renovable, especialmente en un contexto de márgenes ajustados y presupuestos limitados. (p. 9)

Además, la falta de estudios de caso y análisis de costo-beneficio concretos que demuestren el valor y el retorno de la inversión de las aplicaciones de IA en energías renovables puede obstaculizar su adopción por parte de las empresas y los inversores (Agarwal *et al.*, 2020).

Para superar estos obstáculos, es necesario un esfuerzo colaborativo entre la industria, la academia y el gobierno para abordar los desafíos técnicos y económicos de la adopción de la IA en energías renovables. Esto incluye iniciativas para mejorar la calidad y accesibilidad de los datos, desarrollar estándares y protocolos para su intercambio y análisis, promover la investigación y el desarrollo de algoritmos de IA robustos y adaptados a las características específicas de los sistemas de energía renovable, y establecer mecanismos de financiación e incentivos para fomentar la adopción y la inversión en soluciones basadas en IA (Hannan *et al.*, 2021).

En consecuencia, aunque la IA tiene un gran potencial para transformar y optimizar los sistemas de energía renovable, su adopción generalizada aún enfrenta obstáculos técnicos y económicos significativos. Abordar estos desafíos requerirá un enfoque multidisciplinario y colaborativo que involucre a todas las partes interesadas del sector energético y promueva la innovación, la estandarización y la inversión en soluciones basadas en IA.

5.2. Implicaciones éticas

La aplicación de la IA en los sistemas de energía renovable no solo conlleva desafíos técnicos y económicos, sino que también plantea importantes consideraciones éticas que deben abordarse para garantizar un desarrollo y uso responsable, y beneficioso de estas tecnologías.

Una de las principales preocupaciones éticas es la privacidad y seguridad de los datos utilizados por los sistemas de IA en energías renovables. Según Vinuesa *et al.* (2020):

los algoritmos de IA requieren grandes cantidades de datos de usuarios, dispositivos y sistemas energéticos, que pueden incluir información sensible y personal, como patrones de consumo, ubicación y preferencias, lo que plantea riesgos de privacidad y ciberseguridad si estos datos no se recopilan, almacenan y procesan de manera adecuada. (p. 2)

Es necesario establecer marcos legales y éticos sólidos para garantizar la protección de la privacidad de los usuarios, la seguridad de los datos y la

prevención de usos no autorizados o malintencionados de la información en el contexto de la IA aplicada a energías renovables (Vinuesa *et al.*, 2020).

Otra consideración ética es la transparencia y explicabilidad de los algoritmos y modelos de IA utilizados en los sistemas de energía renovable. Según Asilomar (2017):

la opacidad y la falta de comprensión de algunos sistemas de IA, especialmente los basados en aprendizaje profundo, pueden generar desconfianza y preocupaciones sobre la equidad, la imparcialidad y la rendición de cuentas de las decisiones y acciones tomadas por estos sistemas. (p. 3)

Es importante desarrollar y aplicar principios de transparencia y explicabilidad en el diseño y uso de los algoritmos de IA en energías renovables, para que los operadores, reguladores y usuarios puedan entender y auditar su funcionamiento y detectar posibles sesgos o errores (Asilomar, 2017).

Además, la aplicación de la IA en energías renovables también puede tener implicaciones éticas relacionadas con el impacto en el empleo y la distribución de los beneficios. Según Ding *et al.* (2021):

la automatización y optimización de los sistemas de energía renovable mediante IA puede llevar a la pérdida de puestos de trabajo en algunas áreas, como la operación y el mantenimiento manual, lo que plantea desafíos de transición justa y equitativa para los trabajadores afectados. (p. 10)

Es necesario desarrollar políticas y estrategias para anticipar y mitigar los impactos negativos de la IA en el empleo en el sector energético, y garantizar que los beneficios económicos y sociales de estas tecnologías se distribuyan de manera justa y equitativa (Ding *et al.*, 2021).

Para abordar estas implicaciones éticas, es fundamental establecer principios y directrices éticas para el desarrollo y uso de la IA en energías renovables, que promuevan la transparencia, la equidad, la responsabilidad y el beneficio social. Esto implica la participación de todas las partes interesadas, incluyendo la industria, la academia, el gobierno y la sociedad civil, en la discusión y definición de estos principios y en la supervisión de su implementación (Vinuesa *et al.*, 2020).

En conclusión, la aplicación de la IA en los sistemas de energía renovable plantea importantes desafíos éticos que deben abordarse de manera proactiva y responsable. Garantizar la privacidad y seguridad de los datos, la transparencia y explicabilidad de los algoritmos, y una transición justa y equitativa para los trabajadores afectados son aspectos clave para asegurar que la IA contribuya de manera positiva y sostenible a la transformación del sector energético hacia un futuro más limpio y renovable.

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Glosario de términos

Algoritmos de optimización: Técnicas computacionales utilizadas para encontrar la mejor solución a un problema dado, teniendo en cuenta ciertas restricciones y objetivos.

Algoritmos evolutivos: Métodos de optimización inspirados en los principios de la evolución biológica, como la selección natural y la mutación genética.

Aprendizaje automático: Campo de la IA que permite a los sistemas aprender y mejorar a partir de datos, sin ser programados explícitamente.

Aprendizaje por refuerzo: Tipo de aprendizaje automático en el que un agente aprende a tomar decisiones óptimas mediante la interacción con un entorno y la recepción de recompensas o penalizaciones.

Aprendizaje profundo: Subconjunto del aprendizaje automático que utiliza redes neuronales artificiales con múltiples capas para aprender representaciones jerárquicas de los datos.

Aprendizaje supervisado: Tipo de aprendizaje automático en el que los algoritmos aprenden a partir de datos etiquetados, es decir, ejemplos con entradas y salidas conocidas.

Ciencia de datos: Campo interdisciplinario que combina métodos estadísticos, aprendizaje automático y conocimiento del dominio para extraer conocimientos y tomar decisiones a partir de datos.

Control predictivo: Técnica de control que utiliza modelos matemáticos para predecir el comportamiento futuro de un sistema y determinar las acciones de control óptimas.

Energías renovables: Fuentes de energía que se obtienen de recursos naturales virtualmente inagotables, como el sol, el viento, el agua, el calor de la tierra y la biomasa.

Gemelo digital: Representación virtual exacta de un objeto físico, proceso o sistema real. Utiliza datos en tiempo real y modelos digitales para simular, analizar y predecir el comportamiento del equivalente físico, facilitando mejoras en diseño, operación y mantenimiento a través de la retroalimentación constante.

IA: Campo de la informática que busca desarrollar sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como el aprendizaje, el razonamiento y la resolución de problemas.

Mantenimiento predictivo: Estrategia de mantenimiento que utiliza la supervisión y el análisis continuo del estado de los equipos para predecir cuándo es probable que se produzcan fallos y realizar tareas de mantenimiento antes de que ocurran.

Procesamiento del lenguaje natural: Campo de la IA que se ocupa de la interacción entre las computadoras y los lenguajes humanos, incluyendo tareas como el análisis de sentimientos, la traducción automática y la generación de texto.

Redes neuronales artificiales: Modelos computacionales inspirados en la estructura y funcionamiento del cerebro humano, compuestos por nodos interconectados (neuronas artificiales) que procesan y transmiten información.

Redes neuronales convolucionales: Tipo de red neuronal artificial especialmente adecuada para procesar datos con una estructura de cuadrícula, como imágenes, y que utiliza operaciones de convolución para extraer características relevantes.

Redes neuronales recurrentes: Tipo de red neuronal artificial que puede procesar secuencias de datos, como series temporales o texto, y que utiliza conexiones de retroalimentación para mantener información sobre estados anteriores.

Sistemas expertos: Programas informáticos que emulan la toma de decisiones de un experto humano en un dominio específico, utilizando una base de conocimientos y un motor de inferencia.

Teoría de juegos: Marco matemático para analizar situaciones estratégicas en las que múltiples agentes toman decisiones que afectan a los resultados de los demás.

Transparencia algorítmica: Principio que promueve la apertura y comprensibilidad de los algoritmos y procesos automatizados. Implica que las decisiones y resultados generados por sistemas algorítmicos sean accesibles y entendibles para usuarios y partes interesadas, permitiendo identificar cómo se obtienen los resultados y detectar posibles sesgos o errores.

Visión por computadora: Campo de la IA que se ocupa de permitir que las computadoras interpreten y comprendan información visual del mundo, como imágenes y videos.

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Índice de abreviaturas

IA: Inteligencia Artificial

AG: Algoritmos Genéticos

ARIMA: Autoregressive Integrated Moving Average (Modelo Autorregresivo Integrado de Media Móvil)

CNN: Convolutional Neural Network (Red Neuronal Convolutacional)

CO₂: Dióxido de Carbono

DER: Distributed Energy Resources (Recursos Energéticos Distribuidos)

GEA: Geothermal Energy Association (Asociación de Energía Geotérmica)

GW: Gigavatios

GWEC: Global Wind Energy Council (Consejo Global de Energía Eólica)

HVAC: Heating, Ventilation, and Air Conditioning (Calefacción, Ventilación y Aire Acondicionado)

IEA: International Energy Agency (Agencia Internacional de Energía)

IHA: International Hydropower Association (Asociación Internacional de Hidroelectricidad)

IPCC: Intergovernmental Panel on Climate Change (Panel Intergubernamental sobre Cambio Climático)

IRENA: International Renewable Energy Agency (Agencia Internacional de Energías Renovables)

LSTM: Long Short-Term Memory (Memoria a Largo Plazo)

MAPE: Mean Absolute Percentage Error (Error Medio Absoluto Porcentual)

MPC: Model Predictive Control (Control Predictivo basado en Modelos)

MW: Megavatios

NREL: National Renewable Energy Laboratory (Laboratorio Nacional de Energías Renovables)

PSO: Particle Swarm Optimization (Optimización de Enjambre de Partículas)

R-CNN: Region-based Convolutional Neural Network (Red Neuronal Convolutacional basada en Regiones)

RF: Random Forest (Bosques Aleatorios)

RNA: Red Neuronal Artificial

RNN: Recurrent Neural Network (Red Neuronal Recurrente)

SVM: Support Vector Machine (Máquina de Vectores de Soporte)

TI: Tecnologías de la Información

ARCHIVO SÓLO PARA VISUALIZACIÓN DIGITAL

Índice de autores

Capítulo 1:

- Alpaydin, E. (2020)
Goodfellow, I., Bengio, Y., & Courville, A. (2016)
Haykin, S. (2009)
McCarthy, J. (2007)
Mitchell, T. M. (1997)
Nilsson, N. J. (2010)
Russell, S., & Norvig, P. (2021)

Capítulo 2:

- GEA. (2021)
GWEC. (2021)
IEA. (2020)
IHA. (2021)
IPCC. (2011)
IRENA. (2020)
IRENA. (2021)
Kabir, E., Kumar, P., Kumar, S., Adelodun, A. A., & Kim, K. H. (2018)
NREL. (2021)
REN21. (2021)

Capítulo 3:

- Antonopoulos, I., Robu, V., Couraud, B., Kirli, D., Norbu, S., Kiprakis, A., ...
& Wattam, S. (2020)
Canizo, M., Conde, E., Charramendieta, S., & Heredia, F. J. (2020)
Dai, Q., Jiang, P., Wang, J., & Qian, Y. (2021)
Foley, A. M., Leahy, P. G., Marvuglia, A., & McKeogh, E. J. (2012)
Hou, P., Hu, W., Soltani, M., Chen, C., & Chen, Z. (2019)
IEA. (2019)

- Jiang, H., Hu, Y., Shen, X., Liu, S., & Li, Z. (2021)
- Jimenez, A. A., Muñoz, C. Q. G., & Marquez, F. P. G. (2021)
- Ramchurn, S. D., Pollitt, M., Nolden, C., & Sen, S. (2021)
- Sinha, S., & Chandel, S. S. (2015)
- Stetco, A., Dinmohammadi, F., Zhao, X., Robu, V., Flynn, D., Barnes, M., Keane, J., & Nenadic, G. (2019)
- Voyant, C., Notton, G., Kalogirou, S., Nivet, M. L., Paoli, C., Motte, F., & Fouilloy, A. (2017)
- Wang, L., Zhan, Y., Dai, Q., & Chang, W. (2019)
- Wang, Y., Chen, Q., Hong, T., & Kang, C. (2018)
- Youssef, A. M., El-Telbany, M., & Zekry, A. (2021)

Capítulo 4:

- Abuella, M., & Chowdhury, B. (2019)
- Canizo, M., Conde, E., Charramendieta, S., & Heredia, F. J. (2020)
- Cardoso, G., Rolim, J. G., & Zürn, H. H. (2021)
- Carvajal, G., Geiger, S., & Corbett, P. W. (2020)
- Gruber, K., Trummer, C., Kostevsek, M., & Wopienka, E. (2019)
- Hossain, M. S., Sarker, M. Z. I., Chowdhury, N. H., Muktadir, M. A., & Sharma, S. K. (2021)
- Mittal, A. (2010)
- Raitila, J., Heiskanen, V. P., Routa, J., Kolström, M., & Sikanen, L. (2021)
- Toppi, T., Polverini, D., Chiappini, D., & Mazzoleni, A. P. (2021)
- Zhang, J., Luo, Z., Jiao, J., & Shen, C. (2019)

Capítulo 5:

- Agarwal, S., Vashishtha, P., & Mishra, S. N. (2020)
- Asilomar. (2017)
- Ding, J., Li, Z., Ding, G., & Tan, Y. (2021)
- Hannan, M. A., Abbas, S. M., Ker, P. J., Rahman, M. S. A., Mansor, M., Ayob, A., ... & Rahman, M. M. (2021)
- Vinuesa, R., Azizpour, H., Leite, I., Balaam, M., Dignum, V., Domisch, S., ... & Nerini, F. F. (2020)

Referencias

- Abuella, M., & Chowdhury, B. (2019). Solar power forecasting using recurrent neural networks with long short-term memory. 2019 *IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)*, 1-5. <https://doi.org/10.1109/ISGT.2019.8791552>
- Agarwal, S., Vashishtha, P., & Mishra, S. N. (2020). Artificial intelligence in renewable energy: Challenges and opportunities. *IEEE Access*, 8, 175427-175446. <https://doi.org/10.1109/ACCESS.2020.3025917>
- Akhter, F., Mekhilef, S., Shah, R., & Seyedmahmoudian, M. (2021). Deep learning approaches for fault diagnosis in photovoltaic systems. *Renewable and Sustainable Energy Reviews*, 136, 110422.
- Akhter, M. N., Mekhilef, S., Mokhlis, H., & Shah, N. M. (2021). Intelligent predictive maintenance for solar photovoltaic systems using deep learning. *IEEE Access*, 9, 1-20. <https://doi.org/10.1109/ACCESS.2021.3051058>
- Alpaydin, E. (2020). *Introduction to machine learning* (4th ed.). MIT Press.
- Antonopoulos, I., Robu, V., Couraud, B., Kirli, D., Norbu, S., Kiprakis, A., ... & Wattam, S. (2020). Artificial intelligence and machine learning approaches to energy demand-side response: A systematic review. *Renewable and Sustainable Energy Reviews*, 130, 109899. <https://doi.org/10.1016/j.rser.2020.109899>
- Ariturk, M. S. (2019). *Optimizing the production and injection wells flow rates in geothermal field using artificial intelligence*. West Virginia University.
- Asilomar. (2017). Asilomar AI Principles. Future of Life Institute. <https://futureoflife.org/ai-principles/>
- Aynew, E., & Berhanu, M. (2022). Application of artificial intelligent technique to maximize power yielding ability of wind turbine. *Energy Sources Part A Recovery Utilization and Environmental Effects*, 44(1), 2115–2132. <https://doi.org/10.1080/15567036.2022.2058123>
- Banco Mundial. (2021). Renewable energy: A key climate solution. <https://www.worldbank.org/en/topic/energy/publication/renewable-energy-a-key-climate-solution>

- Barsali, S., De Marco, A., Giglioli, R., Ludovici, G., & Possenti, A. (2015). Dynamic modelling of biomass power plant using micro gas turbine. *Renewable Energy*, 80, 806–818. <https://doi.org/10.1016/j.renene.2015.02.064>
- Bosatelli, F., Romano, S. L., Bonacci, F., Infante, C. B., Cosmai, R., & Niccolai, A. (2021). Enel green power's AI tool for anomaly detection on PV plant thermographies collected with UAS. 2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), 1–3
- Bose, B. K. (2019). Artificial intelligence applications in renewable energy systems and smart grid – some novel applications. En *Power Electronics in Renewable Energy Systems and Smart Grid* (pp. 625–675). Wiley. <https://doi.org/10.1002/9781119515661.ch12>
- Buster, G., Siratovich, P., Taverna, N., Rossol, M., Weers, J., Blair, A., Huggins, J., Siega, C., Mannington, W., Urgel, A., Cen, J., Quinao, J., Watt, R., & Akerley, J. (2021). A new modeling framework for Geothermal Operational Optimization with Machine Learning (GOOML). *Energies*, 14(20), 6852. <https://doi.org/10.3390/en14206852>
- Canizo, M., Conde, E., Charramendieta, S., & Heredia, F. J. (2020). Predictive maintenance of wind turbines using machine learning techniques. *Renewable Energy*, 156, 1164–1179. <https://doi.org/10.1016/j.renene.2020.04.111>
- Cardoso, G., Rolim, J. G., & Zürn, H. H. (2021). Deep learning for fault detection and classification in large hydro generators. *Electric Power Systems Research*, 193, 107017. <https://doi.org/10.1016/j.epsr.2021.107017>
- Carvajal, G., Geiger, S., & Corbett, P. W. (2020). Machine learning for geothermal prospectivity mapping in the Taupo Volcanic Zone, New Zealand. *Geothermics*, 88, 101911. <https://doi.org/10.1016/j.geothermics.2020.101911>
- Chen, X., Li, Y., & Jin, K. (2020). Wind farm layout optimization using genetic algorithm with different hub heights. *Renewable Energy*, 146, 1623–1634.
- Dai, L., Li, H., Wang, W., & Yang, W. (2021). Optimal maintenance scheduling of wind turbines using intelligent algorithms. *Energy*, 219, 119568.
- Dai, Q., Jiang, P., Wang, J., & Qian, Y. (2021). Optimizing maintenance strategy for wind farms based on ontology modelling and system dynamics.

- Renewable and Sustainable Energy Reviews*, 144, 110988. <https://doi.org/10.1016/j.rser.2021.110988>
- Darby, S. J. (2018). Smart technology in the home: time for more clarity. *Building Research & Information*, 46(1), 140-147.
- Ding, J., Li, Z., Ding, G., & Tan, Y. (2021). Toward ethical artificial intelligence in renewable energy systems. *Renewable and Sustainable Energy Reviews*, 146, 111153. <https://doi.org/10.1016/j.rser.2021.111153>
- Djenouri, D., Laidi, R., Djenouri, Y., & Balasingham, I. (2019). Machine learning for smart building applications: Review and taxonomy. *ACM Computing Surveys (CSUR)*, 52(2), 1-36. <https://doi.org/10.1145/3311950>
- Energy Information Administration. (2020). *Maintenance Optimization in Renewable Energy Systems*. EIA Publications.
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., Cui, C., Corrado, G., Thrun, S., & Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25(1), 24-29. <https://doi.org/10.1038/s41591-018-0316-z>
- European Commission. (2020). *The role of energy storage in the EU's decarbonisation strategy*. EC Publications.
- Foley, A. M., Leahy, P. G., Marvuglia, A., & McKeogh, E. J. (2012). Current methods and advances in forecasting of wind power generation. *Renewable Energy*, 37(1), 1-8. <https://doi.org/10.1016/j.renene.2011.05.033>
- GEA. (2021). What is geothermal energy? Geothermal Energy Association. <https://www.geothermal.org/what.html>
- Global Wind Energy Council. (2020). *Global Wind Report 2020*. GWEC.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. <http://www.deeplearningbook.org>
- Gruber, K., Trummer, C., Kostevsek, M., & Wopienka, E. (2019). Optimized fuel blends for biomass gasification plants using genetic algorithms. *Biomass and Bioenergy*, 127, 105261. <https://doi.org/10.1016/j.biombioe.2019.105261>
- GWEC. (2021). *Global Wind Report 2021*. Global Wind Energy Council. <https://gwec.net/global-wind-report-2021/>

- Hannan, M. A., Abbas, S. M., Ker, P. J., Rahman, M. S. A., Mansor, M., Ayob, A., ... & Rahman, M. M. (2021). Artificial intelligence applications in renewable energy systems: challenges and future trends. *IET Renewable Power Generation*, 15(7), 1322-1345. <https://doi.org/10.1049/rpg2.12119>
- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson.
- Hossain, M. S., Sarker, M. Z. I., Chowdhury, N. H., Muktedir, M. A., & Sharma, S. K. (2021). Automated fault detection in solar photovoltaic panels using deep learning and thermal images. *Renewable Energy*, 176, 460-479. <https://doi.org/10.1016/j.renene.2021.05.065>
- Hou, P., Chen, C., & Blaabjerg, F. (2019). Optimized placement of wind turbines in large-scale offshore wind farm considering wake effects. *Renewable Energy*, 133, 1029-1040.
- Hou, P., Hu, W., Soltani, M., Chen, C., & Chen, Z. (2019). Combined optimization for offshore wind turbine micro siting. *Applied Energy*, 233-234, 1027-1040. <https://doi.org/10.1016/j.apenergy.2018.10.063>
- Iba, H., & Aranha, C. (2021). Applied Evolutionary Algorithms for Renewable and Sustainable Energy. *Springer Nature*. <https://doi.org/10.1007/978-981-33-4936-3>
- IEA. (2019). Artificial intelligence and big data. International Energy Agency. <https://www.iea.org/reports/artificial-intelligence-and-big-data>
- IEA. (2020). Renewables 2020: Analysis and forecast to 2025. International Energy Agency. <https://www.iea.org/reports/renewables-2020>
- IEA. (2021). Renewables 2021: Analysis and forecasts to 2026. International Energy Agency. <https://www.iea.org/reports/renewables-2021>
- IHA. (2021). Hydropower Status Report 2021. International Hydropower Association. <https://www.hydropower.org/status-report>
- International Electrotechnical Commission. (2019). Artificial Intelligence in Wind Energy. *IEC White Paper*.
- International Energy Agency (IEA). (2019). Artificial Intelligence in Energy. *IEA Publications*.
- IPCC. (2011). *Special Report on Renewable Energy Sources and Climate Change Mitigation*. Intergovernmental Panel on Climate Change. Cambridge University Press. <https://www.ipcc.ch/report/renewable-energy-sources-and-climate-change-mitigation/>

- IPCC. (2021). *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press. <https://www.ipcc.ch/report/sixth-assessment-report-working-group-i/>
- IRENA. (2020). *Renewable Energy and Jobs—Annual Review 2020*. International Renewable Energy Agency. <https://www.irena.org/publications/2020/Sep/Renewable-Energy-and-Jobs-Annual-Review-2020>
- IRENA. (2021). *Renewable Capacity Statistics 2021*. International Renewable Energy Agency. <https://www.irena.org/publications/2021/March/Renewable-Capacity-Statistics-2021>
- IRENA. (2021). *Renewable Power Generation Costs in 2020*. International Renewable Energy Agency. <https://www.irena.org/publications/2021/Jun/Renewable-Power-Costs-in-2020>
- Jha, S. K., Bilalovic, J., Jha, A., Patel, N., & Zhang, H. (2020). Renewable energy: Present research and future scope of Artificial Intelligence. *Renewable and Sustainable Energy Reviews*, 109, 1-13. <https://doi.org/10.1016/j.rser.2020.109780>
- Jiang, H., Hu, Y., Shen, X., Liu, S., & Li, Z. (2021). Intelligent fault diagnosis for power grid based on graph convolutional network and expert knowledge. *IEEE Transactions on Power Systems*, 36(2), 1171-1181. <https://doi.org/10.1109/TPWRS.2020.3019411>
- Jimenez, A. A., Muñoz, C. Q. G., & Marquez, F. P. G. (2021). Machine learning for wind turbine blades maintenance management. *Energies*, 14(3), 1-24. <https://doi.org/10.3390/en14030766>
- Kabir, E., Kumar, P., Kumar, S., Adelodun, A. A., & Kim, K. H. (2018). Solar energy: Potential and future prospects. *Renewable and Sustainable Energy Reviews*, 82, 894-900. <https://doi.org/10.1016/j.rser.2017.09.094>
- Kamel, S., & Dahl, C. (2019). The economics of hybrid power systems for sustainable desert agriculture in Egypt. *Energy*, 169, 423-438.
- Khan, I., Zhu, H., Khan, D., & Panjwani, M. K. (2017). Photovoltaic power prediction by cascade forward artificial neural network. 2017 International Conference on Information and Communication Technologies (ICICT), 145–149.

- Kumar, K., & Saini, R. (2021). Application of artificial intelligence for the optimization of hydropower energy generation. *EAI Endorsed Transactions on Industrial Networks and Intelligent Systems*, 8(28), 170560. <https://doi.org/10.4108/eai.6-8-2021.170560>
- Lee, D., Kim, J., & Lee, K. (2020). Big data analytics for renewable energy forecasting: Methods, applications, and future directions. *Energies*, 13(16), 4252.
- Li, B. H., Hou, B. C., Yu, W. T., Lu, X. B., & Yang, C. W. (2020). Applications of artificial intelligence in intelligent manufacturing: A review. *Frontiers of Information Technology & Electronic Engineering*, 21(11), 1567-1581. <https://doi.org/10.1631/FITEE.1900445>
- Li, X., Wang, Y., & Gao, H. (2019). Optimal design of photovoltaic arrays using artificial intelligence algorithms. *Solar Energy*, 188, 545-554.
- Litman, T. (2021). Autonomous vehicle implementation predictions: Implications for transport planning. Victoria Transport Policy Institute. <https://www.vtpi.org/avip.pdf>
- McCarthy, J. (2007). What is artificial intelligence? <http://www-formal.stanford.edu/jmc/whatisai/>
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the Dartmouth summer research project on artificial intelligence, august 31, 1955. *AI Magazine*, 27(4), 12-14. <https://doi.org/10.1609/aimag.v27i4.1904>
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill
- Mittal, A. (2010). Optimization of the layout of large wind farms using a genetic algorithm. *Wind Energy*, 13(6), 573-582. <https://doi.org/10.1002/we.369>
- Nilsson, N. J. (2010). *The quest for artificial intelligence: A history of ideas and achievements*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511819346>
- NREL. (2021). Solar Energy Basics. National Renewable Energy Laboratory. <https://www.nrel.gov/research/re-solar.html>
- Nusiaputra, Y., Wiemer, H.-J., & Kuhn, D. (2014). Thermal-economic modularization of small, Organic Rankine Cycle power plants for mid-enthalpy geothermal fields. *Energies*, 7(7), 4221-4240. <https://doi.org/10.3390/en7074221>

- Palensky, P., & Dietrich, D. (2011). Demand side management: Demand response, intelligent energy systems, and smart loads. *IEEE Transactions on Industrial Informatics*, 7(3), 381-388.
- Perez-Lombard, L., Ortiz, J., & Pout, C. (2017). A review on buildings energy consumption information. *Energy and Buildings*, 40(3), 394-398.
- Raitila, J., Heiskanen, V. P., Routa, J., Kolström, M., & Sikanen, L. (2021). Predicting biomass quality and heating value with machine learning models based on supply chain data. *Biomass and Bioenergy*, 150, 106106. <https://doi.org/10.1016/j.biombioe.2021.106106>
- Ramchurn, S. D., Pollitt, M., Nolden, C., & Sen, S. (2021). AI for Economic Dispatch in the Smart Grid. *Artificial Intelligence for the Smart Grid*, 1-34. https://doi.org/10.1142/9789811227172_0001
- REN21. (2021). Renewables 2021 Global Status Report. REN21 Secretariat. <https://www.ren21.net/reports/global-status-report/>
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Singh, P., & Kumar, Y. (2020). Optimization of hybrid renewable energy system using artificial intelligence techniques. *Energy*, 213, 118724.
- Sinha, S., & Chandel, S. S. (2015). Review of recent trends in optimization techniques for solar photovoltaic wind based hybrid energy systems. *Renewable and Sustainable Energy Reviews*, 50, 755-769. <https://doi.org/10.1016/j.rser.2015.05.040>
- Smart Grid Forum. (2019). *Advancements in Predictive Maintenance for Electrical Networks*. SGF Reports.
- Smithers, T., & Tang, M. X. (1992). AI-based design and simulation of hydroelectric power systems. *IFAC Proceedings Volumes*, 25(1), 189-192. [https://doi.org/10.1016/s1474-6670\(17\)50451-6](https://doi.org/10.1016/s1474-6670(17)50451-6)
- SolarPower Europe. (2019). *Global Market Outlook for Solar Power 2019-2023*.
- Stetco, A., Dinmohammadi, F., Zhao, X., Robu, V., Flynn, D., Barnes, M., Keane, J., & Nenadic, G. (2019). Machine learning methods for wind turbine condition monitoring: A review. *Renewable Energy*, 133, 620-635. <https://doi.org/10.1016/j.renene.2018.10.047>
- Stone, P., Brooks, R., Brynjolfsson, E., Calo, R., Etzioni, O., Hager, G., Hirschberg, J., Kalyanakrishnan, S., Kamar, E., Kraus, S., Leyton-Brown,

- K., Parkes, D., Press, W., Saxenian, A., Shah, J., Tambe, M., & Teller, A. (2016). *Artificial intelligence and life in 2030: One hundred years study on artificial intelligence*. Stanford University. <https://ai100.stanford.edu/2016-report>
- TopCable. (2023, 15 febrero). La biomasa, fuente de energía renovable de gran potencial | Top Cable. Cables y consejos eléctricos. By Top Cable. <https://www.topcable.com/blog-electric-cable/la-biomasa-fuente-de-energia-renovable-de-gran-potencial/>
- Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44-56. <https://doi.org/10.1038/s41591-018-0300-7>
- Toppi, T., Polverini, D., Chiappini, D., & Mazzoleni, A. P. (2021). Model predictive control for geothermal power plant optimization: A case study. *Renewable Energy*, 168, 1131-1141. <https://doi.org/10.1016/j.renene.2020.12.105>
- Ulbricht, R., Hempel, D., Böhme, M., Jurczyk, M., & Rehberg, M. (2019). Artificial intelligence for photovoltaic power prediction. In 2019 IEEE International Conference on Big Data (Big Data) (pp. 523-528). IEEE. <https://doi.org/10.1109/BigData47090.2019.9006355>
- Velasquez, V., & Flores, W. (2022). Machine learning approach for predictive maintenance in hydroelectric power plants. 2022 IEEE Biennial Congress of Argentina (ARGENCON), 1–6.
- Vinuesa, R., Azizpour, H., Leite, I., Balaam, M., Dignum, V., Domisch, S., ... & Nerini, F. F. (2020). The role of artificial intelligence in achieving the Sustainable Development Goals. *Nature Communications*, 11(1), 1-10. <https://doi.org/10.1038/s41467-019-14108-y>
- Voyant, C., Notton, G., Kalogirou, S., Nivet, M. L., Paoli, C., Motte, F., & Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy*, 105, 569-582. <https://doi.org/10.1016/j.renene.2016.12.095>
- Wang, L., Zhan, Y., Dai, Q., & Chang, W. (2019). Forecasting solar radiation using an improved deep learning model. In 2019 14th IEEE Conference on Industrial Electronics and Applications (ICIEA) (pp. 1626-1630). IEEE. <https://doi.org/10.1109/ICIEA.2019.8834162>

- Wang, X., & Wang, L. (2021). Artificial intelligence in manufacturing: A review and perspective. *International Journal of Advanced Manufacturing Technology*, 116(1), 1-18. <https://doi.org/10.1007/s00170-021-07234-9>
- Wang, Y., Chen, Q., Hong, T., & Kang, C. (2018). Review of smart meter data analytics: Applications, methodologies, and challenges. *IEEE Transactions on Smart Grid*, 10(3), 1433-1446. <https://doi.org/10.1109/TSG.2018.2818167>
- Wu, Z., Zhang, C., Alkahtani, M., Hu, Y., & Zhang, J. (2020). Cost effective offline reconfiguration for large-scale non-uniformly aging photovoltaic arrays efficiency enhancement. *IEEE access: practical innovations, open solutions*, 8, 80572–80581. <https://doi.org/10.1109/access.2020.2991089>
- Yang, D., Kleissl, J., Gueymard, C. A., Pedro, H. T. C., & Coimbra, C. F. M. (2018). History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining. *Solar Energy*, 168, 60-101.
- Yonce, J., Walters, M., & Venayagamoorthy, G. K. (2023). Short-term prediction of solar photovoltaic power generation using a digital twin. 2023 North American Power Symposium (NAPS), 1–6. DOI: 10.1109/NAPS58826.2023.10318632
- Youssef, A. M., El-Telbany, M., & Zekry, A. (2021). Implementing artificial intelligence in photovoltaic system design: A review. *Renewable and Sustainable Energy Reviews*, 150, 111433. <https://doi.org/10.1016/j.rser.2021.111433>
- Yurtsever, E., Lambert, J., Carballo, A., & Takeda, K. (2020). A survey of autonomous driving: Common practices and emerging technologies. *IEEE Access*, 8, 58443-58469. <https://doi.org/10.1109/ACCESS.2020.2983149>
- Zhang, J., Luo, Z., Jiao, J., & Shen, C. (2019). Short-term water inflow prediction for hydropower reservoir using a hybrid model based on artificial neural network and particle swarm optimization. *Water Resources Management*, 33(4), 1393-1412. <https://doi.org/10.1007/s11269-018-2176-1>



COLEGIO DE INGENIEROS DEL PERÚ

Av. Arequipa 4947, Miraflores
(01) 445-6540 • 445-5540
www.cip.org.pe

ISBN: 978-612-49780-4-3



9 786124 978043