



Diseño de algoritmos basados en técnicas de aprendizaje profundo para la predicción de energía fotovoltaica en zonas aisladas del Ecuador

Guanoluisa Pineda, Richard Daniel

Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica, Automatización y Control

Trabajo de titulación, previo a la obtención del título de Ingeniero en Electrónica,
Automatización y Control

Ing. Arcos Avilés, Diego Gustavo, PhD.

13 de febrero del 2023

Informe de originalidad

NOMBRE DEL CURSO

Revision Tesis

NOMBRE DEL ALUMNO

RICHARD DANIEL GUANOLUISA PINEDA

NOMBRE DEL ARCHIVO

RICHARD DANIEL GUANOLUISA PINEDA - Tesis_Richard_Guanoluisa

SE HA CREADO EL INFORME

6 feb 2023



Resumen

Fragmentos marcados	14	3 %
Fragmentos citados o entrecomillados	24	4 %

Coincidencias de la Web

issuu.com	8	1 %
ibm.com	4	0,7 %
mathworks.com	3	0,6 %
un.org	3	0,5 %
mheducation.es	3	0,5 %
reisdigital.es	2	0,5 %
slideshare.net	2	0,4 %
docplayer.es	1	0,3 %
wordpress.com	1	0,3 %
uned.es	1	0,2 %
cepal.org	1	0,2 %
pactomundial.org	1	0,2 %
unirioja.es	1	0,2 %
epl.edu.ec	1	0,1 %
brainly.lat	1	0,1 %
ujaen.es	1	0,1 %
cienciacanaria.es	1	0,1 %
fing.edu.uy	1	0,1 %
autoconsumosi.com	1	0,1 %
bookdown.org	1	0,1 %



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica, Automatización y Control

Certificación

Certifico que el trabajo de titulación: "Diseño de algoritmos basados en técnicas de aprendizaje profundo para la predicción de energía fotovoltaica en zonas aisladas del Ecuador" fue realizado por el señor Guanoluisa Pineda, Richard Daniel; el mismo que cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, además fue revisado y analizado en su totalidad por la herramienta de prevención y/o verificación de similitud de contenidos; razón por la cual me permito acreditar y autorizar para que se lo sustente públicamente.

Sangolquí, 13 de febrero de 2023

Firma:



**Diego Gustavo Arcos
AVILÉS**

.....
Ing. Arcos Avilés, Diego Gustavo Ph. D.

C. C. 1710879444



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica, Automatización y Control

Responsabilidad de Autoría

Yo, **Guanoluisa Pineda, Richard Daniel**, con cédula de ciudadanía n° 1724293483, declaro que el contenido, ideas y criterios del trabajo de titulación: **Diseño de algoritmos basados en técnicas de aprendizaje profundo para la predicción de energía fotovoltaica en zonas aisladas del Ecuador** es de mi autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Sangolquí, 13 de febrero de 2023

Firma

Guanoluisa Pineda Richard Daniel

C.C.: 1724293483



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica, Automatización y Control

Autorización de Publicación

Yo **Guanoluisa Pineda, Richard Daniel**, con cédula de ciudadanía n° 1724293483, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **Diseño de algoritmos basados en técnicas de aprendizaje profundo para la predicción de energía fotovoltaica en zonas aisladas del Ecuador** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, 13 de febrero de 2023

Firma

Guanoluisa Pineda Richard Daniel

C.C.: 1724293483

Dedicatoria

A mi madre Marilú, mi padre Luis, mis hermanos Doris, Carolina y Sebastián; y a mi sobrina Daniela.

Agradecimiento

A mi madre Marilú, mis hermanos Doris, Carolina y Sebastián que me brindaron su apoyo incondicional y demás familiares que me acompañaron durante todo el trayecto para conseguir este objetivo.

A mis amigos, compañeros y profesores de la universidad con los cuales compartí gratos momentos.

Finalmente, agradezco a mi tutor Ing. Diego Arcos por su soporte, paciencia y tiempo dedicado en el desarrollo de este trabajo.

Índice de Contenido

Similitud de contenido con herramienta anti plagio	2
Certificación	3
Responsabilidad de Autoría	4
Autorización de Publicación	5
Dedicatoria.....	6
Agradecimiento.....	7
Resumen	15
Abstract.....	16
Capítulo I: Marco Metodológico.....	17
Antecedentes	17
Justificación e importancia.....	22
Alcance	25
Objetivos	27
<i>General</i>	27
<i>Específicos</i>	27
Estado del Arte.....	27
Capítulo II: Marco Conceptual.....	35
Energías renovables.....	35
<i>Energía solar</i>	38
<i>Conceptos</i>	38
<i>Energía solar fotovoltaica</i>	40
<i>Ventajas del uso de energía solar fotovoltaica</i>	43
<i>Desventajas del uso de energía solar fotovoltaica</i>	43
<i>Sistemas fotovoltaicos</i>	43

	9
<i>Componentes</i>	44
<i>Modelo fotovoltaico</i>	46
Energías renovables en Ecuador.....	46
<i>Potencial de energía solar en Ecuador</i>	49
<i>Situación energética en Galápagos</i>	51
Predicción en sistemas de energía.....	54
<i>Pronóstico en el despacho de energía renovable</i>	54
<i>Pronóstico en el dimensionamiento de sistemas de energía</i>	54
<i>Pronóstico y mercados energéticos</i>	55
<i>Pronóstico y dimensionamiento de reservas</i>	55
<i>Importancia de acceso a energía</i>	55
Técnicas de predicción	56
<i>Horizontes de predicción</i>	56
Técnicas de aprendizaje basadas en aprendizaje profundo	57
Redes neuronales recurrentes	57
Redes Memoria de corto-largo plazo	58
LSTM Proyectado.....	60
LSTM Bidireccional.....	61
Gated Recurrent Unit.....	62
Redes neuronales convolucionales	63
Modelos híbridos de aprendizaje profundo	64
Hiperparámetros de aprendizaje.....	64
<i>Funciones de activación</i>	70
Optimización de hiperparámetros	71
<i>Optimización Bayesiana</i>	71

	10
<i>Hold out para optimización</i>	72
<i>Categorización de algoritmos de aprendizaje</i>	73
Procesamiento de datos.....	74
<i>Patrones de series de tiempo</i>	74
<i>Escasez de datos</i>	75
<i>Estandarización de datos</i>	75
<i>Normalización de datos</i>	76
Técnicas de evaluación de modelos.....	76
<i>RMSE</i>	76
<i>MAE</i>	77
<i>MAPE</i>	77
<i>Coefficiente de correlación</i>	77
Capítulo III. Metodología.....	78
Selección de zonas aisladas.....	78
Obtención de datos.....	80
Procesamiento de datos.....	82
Entrenamiento de modelos.....	82
Validación.....	84
Capítulo IV. Resultados.....	85
Conclusiones.....	93
Recomendaciones.....	94
Trabajos futuros.....	95
Reconocimientos.....	95
Bibliografía.....	96
Apéndices.....	104

Índice de tablas

Tabla 1 <i>Objetivos de Desarrollo Sostenible, Agenda 2030, ONU</i>	24
Tabla 2 <i>Potencia nominal de generación de fuentes renovables y no renovables</i>	47
Tabla 3 <i>Fuentes de generación de energía eléctrica en Galápagos</i>	51
Tabla 4 <i>Fuentes de generación de potencia eléctrica en Galápagos</i>	52
Tabla 5 <i>Aporte de fuentes de generación por isla</i>	52
Tabla 6 <i>Comparación desempeño datos normalizados y estandarizados</i>	82
Tabla 7 <i>Hiperparámetros optimizados para predicción</i>	84
Tabla 8 <i>Métricas de desempeño en locación 1</i>	88
Tabla 9 <i>Métricas de desempeño en locación 2</i>	89
Tabla 10 <i>Desempeño computacional</i>	91
Tabla 11 <i>Comparación de desempeño</i>	92

Índice de figuras

Figura 1 <i>Mapa solar del Ecuador</i>	19
Figura 2 <i>Diagrama de flujo para realizar la predicción</i>	26
Figura 3 <i>Conversión y utilización de energía</i>	36
Figura 4 <i>Componentes de la radiación solar</i>	39
Figura 5 <i>Estructura de célula solar</i>	41
Figura 6 <i>Celda solar, módulo, panel y arreglo fotovoltaico</i>	42
Figura 7 <i>Formación de energía solar fotovoltaica</i>	42
Figura 8 <i>Sistemas fotovoltaicos a) Conectados a la red y b) Sistema autónomo</i>	44
Figura 9 <i>Componentes de una instalación fotovoltaica</i>	45
Figura 10 <i>Generación de fuentes renovables y no renovables</i>	48
Figura 11 <i>Porcentaje de acceso a electricidad en cada región en Ecuador</i>	48
Figura 12 <i>Irradiación solar global horizontal anual en Ecuador</i>	50
Figura 13 <i>Distribución de fuentes de generación eléctrica por isla</i>	52
Figura 14 <i>Redes neuronales recurrentes</i>	58
Figura 15 <i>Conexión de información en RNN</i>	58
Figura 16 <i>Modelo de la red Long Short-Term Memory</i>	60
Figura 17 <i>Modelo de la red Long Short-Term Memory Proyectado</i>	61
Figura 18 <i>Modelo de la red Long Short-Term Memory Bidireccional</i>	61
Figura 19 <i>Modelo de la red Gated Recurrent Unit</i>	62
Figura 20 <i>Modelo de la red Convolucional</i>	63
Figura 21 <i>Modelo de la red Híbrida</i>	64
Figura 22 <i>Función de pérdida en Descenso de gradiente</i>	65
Figura 23 <i>Función de pérdida en Descenso de gradiente estocástico</i>	66
Figura 24 <i>Tasa de aprendizaje</i>	69

	13
Figura 25 <i>Funciones de activación de redes neuronales</i>	70
Figura 26 <i>Hold out para selección de modelo de predicción</i>	73
Figura 27 <i>Diagrama de flujo para predicción de energía fotovoltaica</i>	79
Figura 28 <i>Zonas de estudio de caso</i>	79
Figura 29 <i>Portal PVGIS en Islas Galápagos</i>	80
Figura 30 <i>Variación de potencia fotovoltaica para la Isla Santa Cruz</i>	81
Figura 31 <i>Correlación de potencia fotovoltaica entre Isla Santa Cruz e Isla San Cristóbal</i>	81
Figura 32 <i>Hold-out aplicado al conjunto de datos de locación 1</i>	83
Figura 33 <i>Optimización Bayesiana para hiperparámetros del modelo Híbrido</i>	83
Figura 34 <i>RMSE de entrenamiento de los modelos de DL</i>	85
Figura 35 <i>Energía fotovoltaica real y pronosticada para Locación 1</i>	86
Figura 36 <i>Gráfico de correlación para los métodos de DL en locación 1</i>	87
Figura 37 <i>Gráfico de correlación para los métodos de DL en locación 2</i>	89
Figura 38 <i>Comparación de RMSE para los métodos desarrollados</i>	90
Figura 39 <i>Tiempo de entrenamiento para los modelos de DL</i>	91

Acrónimos y siglas

Adam: Estimación adaptativa del momento

ANN: Red neuronal artificial

ARIMA: Media móvil integrada autorregresiva

ARMA: Media móvil autorregresiva

BP: Retro propagación

BO: Optimización Bayesiana

CNN: Red neuronal convolucional

DHI: Irradiación Solar Difusa Horizontal

DL: Aprendizaje profundo

DNI: Irradiación Solar Directa Normal

GD: Descenso de gradiente

GHI: Irradiación Solar Global Horizontal

LSTM: Memoria a corto y largo plazo

LSTMP: Memoria a corto plazo proyectada

GRU: Unidad Recurrente Cerrada

MAE: Error absoluto medio

MAPE: Porcentaje de error absoluto medio

MSE: Error cuadrático medio

ML: Aprendizaje de máquina

NCO: Número de capas ocultas

RMSE: Raíz cuadrada del error cuadrático medio

RNN: Red neuronal recurrente

SNI: Sistema Nacional Interconectado

Resumen

En Ecuador, la generación de electricidad está cubierta principalmente por sistemas hidroeléctricos que alimentan el Sistema Nacional Interconectado (SNI). Sin embargo, algunas áreas aisladas como las Islas Galápagos no están conectadas al SNI. En este sentido, las Islas Galápagos cuentan con una biodiversidad única en el mundo. Sin embargo, sus fuentes primarias de energía se basan en el biogás obtenido a partir de combustibles fósiles, con sus negativas consecuencias a pesar del abundante recurso solar. Por ello, los sistemas de generación basados en fuentes de energía renovables (ER) como la energía fotovoltaica se convierten en una solución eficaz para el suministro de energía eléctrica a estas comunidades sin afectar negativamente a su biodiversidad. En consecuencia, la previsión de energía fotovoltaica es vital para el dimensionamiento e instalación. En este contexto, los modelos de predicción basados en técnicas de aprendizaje profundo (DL) pueden obtener un alto grado de precisión en tareas de predicción energética. Por esta razón, este trabajo presenta el desarrollo de memoria a corto plazo (LSTM), LSTM proyectado (LSTMP), LSTM bidireccional (BiLSTM), Gated Recurrent Unit (GRU), Convolutional Neural Network (CNN) y modelos híbridos para predecir energía fotovoltaica en zonas aisladas del Ecuador. Además, se utiliza la optimización bayesiana (BO) para obtener los hiperparámetros de los modelos y reducir el costo computacional. La metodología aplicada en este trabajo demostró ser capaz de obtener modelos precisos y puede ser utilizada en otras áreas que requieren la tarea de pronóstico como requisito previo para la puesta en marcha de los sistemas fotovoltaicos.

Palabras clave: energía fotovoltaica, predicción de energía, redes neuronales recurrentes, redes neuronales convolucionales, optimización Bayesiana.

Abstract

In Ecuador, electricity generation is mainly covered by hydroelectric systems that feed the National Interconnected System (SIN). However, some isolated areas such as the Galapagos Islands are not connected to the SIN. In this context, the Galapagos Islands have a unique biodiversity in the world. However, its primary sources of energy are based on biogas obtained from fossil fuels, with its negative consequences despite the abundant solar resource. For this reason, generation systems based on renewable energy sources (RES) such as photovoltaic energy become an effective solution for the supply of electricity to these communities without negatively affecting their biodiversity. Consequently, the forecast of photovoltaic energy is vital for dimensioning and installation. In this context, prediction models based on deep learning (DL) techniques can obtain a high degree of accuracy in energy prediction tasks. For this reason, this work presents the development of short-term memory (LSTM), projected LSTM (LSTMP), bidirectional LSTM (BiLSTM), Gated Recurrent Unit (GRU), Convolutional Neural Network (CNN) and hybrid models to predict photovoltaic energy in isolated areas of Ecuador. In addition, Bayesian optimization (BO) is used to obtain the hyperparameters of the models and reduce the computational cost. The methodology applied in this work proved to be capable of obtaining accurate models and can be used in other areas that require the task of forecasting as a prerequisite for the commissioning of photovoltaic systems.

Key words: photovoltaic power, energy forecasting, recurrent neural network, convolutional neural network, Bayesian optimization.

Capítulo I: Marco Metodológico

Antecedentes

Desde principios del siglo XIX el consumo de combustibles fósiles ha aumentado continuamente para aportar al desarrollo de la industria y estilo de vida moderno, a expensas de contaminación, riesgos para la salud y ecología de la tierra. La explotación excesiva de combustibles convencionales contribuye directa e indirectamente al calentamiento global y junto a otros factores conducen al planeta hacia un futuro oscuro (Pandey & Katiyar, 2013).

La situación del cambio climático global es cada vez más severa debido al agotamiento de la energía fósil, por lo que la aplicación de fuentes de energía renovable ha recibido más atención. La especulación sobre el agotamiento de las reservas de combustibles fósiles es motivo de preocupación para la mayoría de los gobiernos y economías, y junto con el cambio climático y los problemas de seguridad energética, se impulsa una campaña masiva por opciones de energía limpia y renovable que complementarían las tecnologías actuales de producción de energía. La problemática de reducir la cantidad de emisiones de CO_2 hace que todo el mundo se concentre en instalar recursos de energía renovable (Hamid Oudjana, Hellal, & Hadj Mahammed, 2014).

Los recursos de energía renovable tienen un enorme potencial y pueden satisfacer la demanda energética mundial actual, pueden mejorar la diversidad en los mercados de suministro de energía, asegurar el suministro de energía sostenible a largo plazo y reducir las emisiones atmosféricas locales y globales. La creciente población y el rápido agotamiento de combustibles fósiles han llevado a investigadores de distintos campos como la ingeniería, economía e industria a perseguir el desarrollo y uso de las energías renovables (Benghanem, 2012), (Mohandes, Rehman, & Halawani, 1998).

Una de las fuentes de energía renovable más competitiva es la energía solar, obtenida de la radiación electromagnética emitida por el Sol, la cual debido a su abundancia aceleró

enormemente la instalación de sistemas fotovoltaicos alrededor del mundo, los cuales, a través de células fotovoltaicas aprovechan la radiación procedente del Sol para convertirla en energía eléctrica, por lo que la ha convertido en una de las fuentes más prometedoras para la generación de energía en aplicaciones residenciales, comerciales, industriales y de transporte.

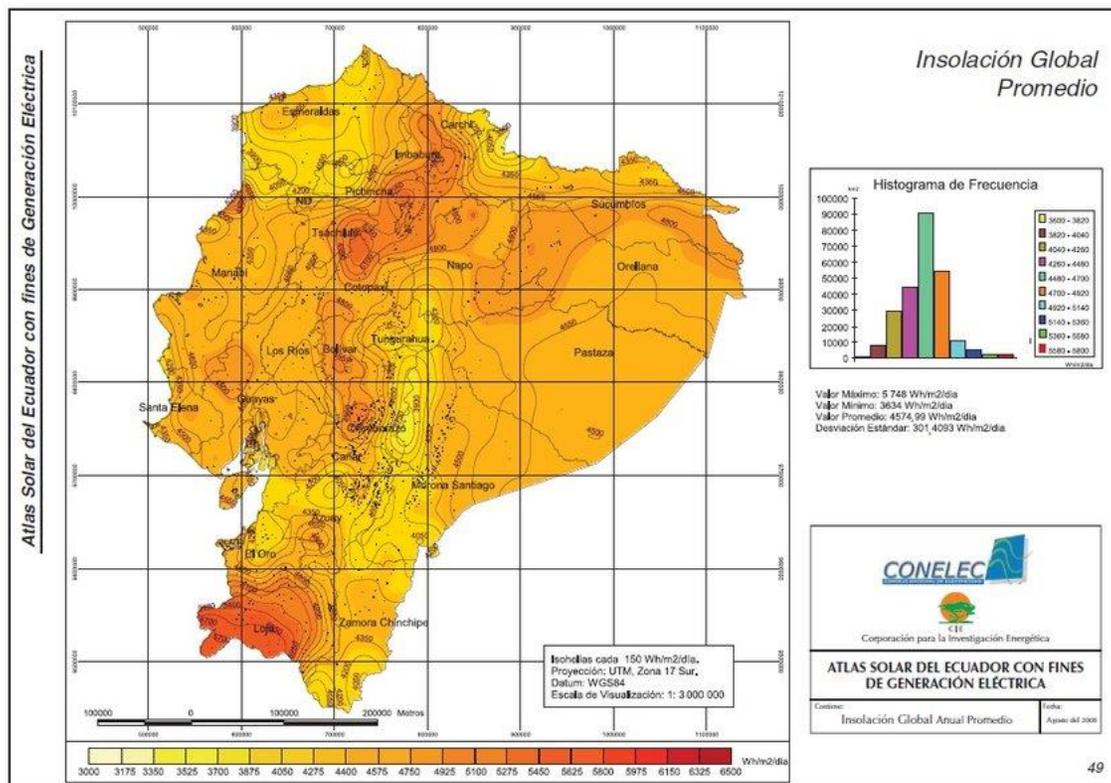
La ubicación del Ecuador permite que nuestro país pueda aprovechar el recurso solar durante todo el año con nivel de radiación promedio de $4574.99 \text{ Wh/m}^2/\text{día}$, tal como muestra la Figura 1, según el ATLAS Solar del Ecuador elaborado por el Consejo Nacional de Electricidad – CONELEC, esta oportunidad de fuente primaria de energía permite el incremento de la capacidad fotovoltaica instalada en centrales de generación, sistemas conectados a la red y/o aislados (Peláez Samaniego & Espinoza, 2015).

Las ventajas de emplear plantas fotovoltaicas para generar electricidad incluyen la no producción de contaminantes durante la operación, son silenciosos, tienen larga vida útil y requieren bajo mantenimiento, además, la energía solar es abundante, libre, limpia y básicamente inagotable (Kumar Sahpp & Kumar Sahoo, 2016).

Sin embargo, la alta penetración de energía provista por sistemas fotovoltaicos también trae nuevos retos para su operación debido a características intermitentes e inciertas correspondientes a factores como la locación y principalmente a las condiciones climáticas de naturaleza estocástica, y en particular, a la variación de temperatura e irradiancia, las cuales tienen un profundo impacto en la calidad de producción de energía eléctrica. Estos retos incluyen: el alto costo de instalación e intermitencia en la generación de energía debido a la sensibilidad de los sistemas fotovoltaicos frente a condiciones meteorológicas, lo que provoca caídas de potencia, sumado a que solo se puede aprovechar la radiación solar durante el día y no durante la noche.

Figura 1

Mapa solar del Ecuador



Nota. Tomado de *Insolación global promedio*, por Consejo Nacional de Electricidad, 2015

La predicción de energía fotovoltaica es una solución eficiente para superar estos desafíos y es reconocida como un prerrequisito para la penetración de sistemas fotovoltaicos a gran escala a la red eléctrica principal (Li, Zhou, Lu, & Yang, 2019). Adicionalmente, la predicción de energía fotovoltaica ha sido ampliamente utilizada en la gestión eficiente de microrredes de diversas formas, ya que consideran la predicción de potencia y previsión de carga para proveer las referencias de funcionamiento a la microrred y coordinar los controladores, también para el diseño de estrategias de control para sistemas de almacenamiento de energía en baterías, por lo que permite lidiar con la variabilidad de la generación solar. Una gestión eficiente permite minimizar los costos operacionales y reducir el

estrés en el sistema mientras se suple la demanda de carga (Palma-Behnke, Benavides, Lanas, & Severino, 2013).

Consecuentemente, la predicción precisa de potencia de salida de módulos fotovoltaicos es de gran importancia para la gestión eficiente de la producción, distribución, dimensionamiento y almacenamiento de la planta, de la misma forma para la toma de decisiones dentro del mercado.

Numerosos métodos han sido reportados en la literatura para la predicción de potencia fotovoltaica, los cuales pueden clasificarse en cuatro clases:

- i) Estadísticos: basado en datos para pronosticar series temporales solares mediante el uso de datos medidos históricos.
- ii) Aprendizaje de Máquina (ML): basados en Redes Neuronales Artificiales (ANN) o Aprendizaje Profundo (DL).
- iii) Modelos físicos: basados en predicción numérica del clima e imágenes satelitales.
- iv) Híbridos: combinación de los métodos anteriores.

En los últimos años, algunos modelos de DL han sido propuestos como las Redes Neuronales Recurrentes (RNN), el cual es un tipo de redes neuronales que explotan la secuencia natural de los datos de entrada, las Redes Memoria a Corto y Largo Plazo (LSTM) son un tipo de RNN capaz de lidiar con recordar información por períodos largos, también es considerado como uno de los modelos de RNN más usado para la predicción de series de datos, el cual calza perfectamente con los problemas de predicción de sistemas de energía fotovoltaicos (Harrou, Kadri, & Sun, 2020). En (Neelamegam & Arasu Amirtham, 2016) se desarrollan diferentes modelos de ANN para predecir la radiación solar en distintas locaciones en India, por consiguiente, las condiciones meteorológicas también son diferentes, como resultado del trabajo se obtuvo que los modelos con ANN realizados predicen de forma

adecuada frente a la variedad de datos y los errores son significativamente bajos. En (Kanchana & Sirisukprasert, 2020) se utiliza el método estadístico Holt-Winters, el cual analiza la tendencia de los datos para realizar la predicción, como locación se tiene el este de Tailandia, el estudio muestra resultados alentadores ya que la simplicidad del algoritmo permitió obtener valores de error pequeños de predicción.

Para evaluar los diferentes métodos generalmente se utilizan los indicadores de error cuadrático medio (RMSE) y el error porcentual absoluto medio (MAPE), el RMSE generalmente se propone como una medida de la calidad de la predicción y se usa con frecuencia para comparar la precisión de diferentes criterios de pronóstico. MAPE tiene la ventaja de ser independiente de la escala y, a menudo, se recomienda su uso como medida de interpretación (Gordillo-Orquera, et al., 2018).

Este tipo de trabajos no es ajeno al contexto nacional, ya que, en (Enríquez, 2019) se desarrolló la previsión de generación fotovoltaica basada en la predicción numérica del clima, donde se midió la temperatura y a través de un piranómetro se midió la irradiancia en una locación de la Universidad de las Fuerzas Armadas ESPE, con estos datos se extrapoló la generación de un generador fotovoltaico según su modelo matemático, se compararon los resultados obtenidos con los datos de medición provistos por el Instituto Nacional de Metrología e Hidrología (INAMHI) donde el error obtenido es menor que el veinte por ciento, lo que corresponde a valores bajos para esta técnica. Además, en (Fabara, Maldonado, Soria, & Tovar, 2019) se realizó la predicción de generación para un sistema fotovoltaico a través de técnicas de minería de datos, para un sistema aislado correspondiente a la central fotovoltaica ubicada en la Comunidad Paragachi, perteneciente al cantón Pimampiro de la provincia Imbabura, el cual, al no contar con un banco de baterías para almacenamiento el sistema abastece únicamente al día a las más de 2000 familias que ahí habitan, este trabajo evalúa las variables que tienen mayor incidencia en la producción de energía que sirven como entrada

para entrenamiento del algoritmo de árboles de decisión mediante bosques aleatorios, con el fin de obtener una mayor rapidez en la predicción, los resultados arrojaron valores de error bajos en el pronóstico, de la misma forma, para evaluar los resultados se utilizan los métodos anteriormente mencionados.

Justificación e importancia

La constante explotación de combustibles fósiles como fuente primaria de energía durante las últimas décadas ha repercutido de manera negativa en el medio ambiente, debido a la emisión de gases contaminantes hacia la atmósfera. Ya que la demanda energética aumenta conforme incrementa la población, se ha vuelto indispensable la investigación, desarrollo y aprovechamiento de nuevas fuentes de energía limpia que satisfagan las necesidades de la población, cuyo estilo de vida depende en gran medida de la utilización de energía eléctrica.

La energía solar constituye una de las fuentes de energía renovable más prometedora en la actualidad, debido a las ventajas de uso frente a la utilización de combustibles fósiles. La practicidad de instalación de sistemas fotovoltaicos trae consigo un amplio campo de utilización, lo que permite aprovechar la energía solar desde aplicaciones residenciales, de transporte hasta industriales.

Si bien la fuente primaria de energía de los sistemas fotovoltaicos es prácticamente inagotable, las condiciones climáticas de comportamiento estocástico repercuten en la estabilidad y entrega de potencia de los sistemas, por lo que prever estos cambios en la entrega de energía es de suma importancia para realizar una correcta planificación, dimensionamiento y gestión de plantas de generación de energía eléctrica según la potencia prevista.

Numerosos estudios realizados muestran la utilidad y ventajas de efectuar la predicción de energía fotovoltaica, sin embargo, no se han explorado las diversas técnicas de predicción basadas en aprendizaje profundo como RNN o LSTM para la previsión de generación en

Ecuador. Con la creciente penetración de sistemas fotovoltaicos en varias aplicaciones, es de suma necesidad contar con herramientas que permitan prever la capacidad de suministro de energía fotovoltaica de forma precisa, en zonas donde no sea posible realizar la instalación de equipos de medición de energía solar o locaciones aisladas que no estén conectadas a la red eléctrica nacional debido a motivos ambientales y/o geográficos que imposibilitan la instalación de plantas tradicionales de generación de energía eléctrica y requieran este servicio.

Por lo anteriormente mencionado, el presente trabajo de investigación tiene como finalidad desarrollar algoritmos de previsión de generación de energía fotovoltaica basados en técnicas de aprendizaje profundo: Redes Neuronales Recurrentes y Memoria a Corto y Largo Plazo, con el propósito de determinar las ventajas que presentan estos algoritmos frente a otros y a su vez que sirva como referente para realizar predicciones en una zona aislada del Ecuador. A través del pronóstico realizado es posible dimensionar plantas de generación eléctricas que sean capaces de abastecer la demanda energética en una locación determinada, ya sean instalaciones aisladas o que puedan integrarse a la red eléctrica nacional, con el fin de aprovechar al máximo la disponibilidad de energía solar que tiene el país.

Adicionalmente, se considera la Agenda 2030 sobre el Desarrollo Sostenible de la Organización de las Naciones Unidas (ONU) (ONU, 2022), al desarrollar el presente proyecto se tiene como base el fomento y la utilización de fuentes de energía renovable para la planificación y posterior abastecimiento de energía a comunidades aisladas del país, de forma no contaminante. También, como alternativa a las fuentes de energía tradicionales que afectan de forma negativa al entorno y calidad de vida de las personas como su aporte al cambio climático. Al aprovechar y utilizar como fuente primaria los sistemas fotovoltaicos, se supe de energía a comunidades e industria de forma limpia y segura. Al utilizar algoritmos de previsión basados en aprendizaje profundo se emplea tecnología computacional para prever la generación, lo que fomenta la innovación en el sector energético. Con lo anteriormente

mencionado, se consideran los objetivos mostrados en la Tabla 1, esto con el fin de crear un ecosistema sostenible en el Ecuador.

Tabla 1

Objetivos de Desarrollo Sostenible, Agenda 2030, ONU

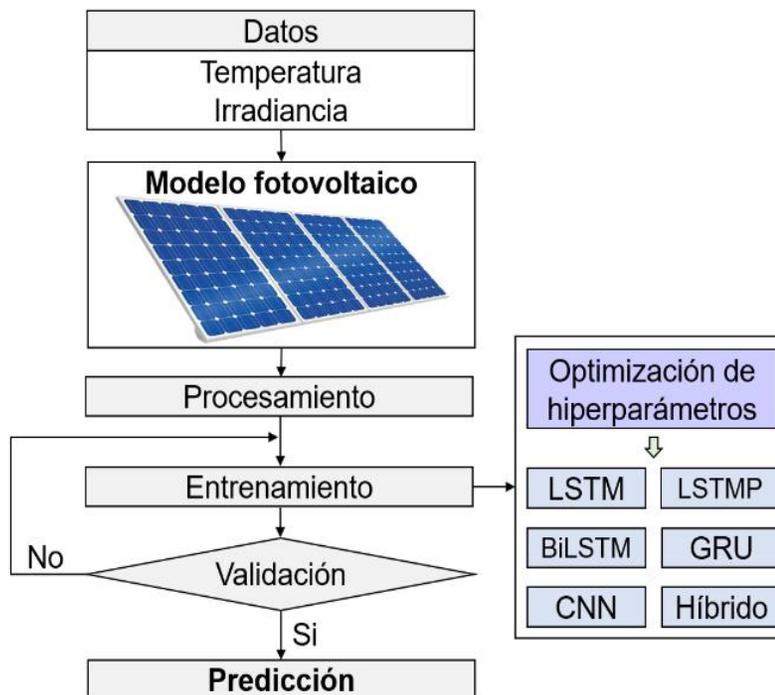
	Objetivo	Metas
7. Energía asequible y no contaminante	Garantizar el acceso a una energía asequible, segura, sostenible y moderna.	De aquí a 2030, garantizar el acceso universal a servicios energéticos asequibles, fiables y modernos y aumentar considerablemente la proporción de energía renovable en el conjunto de fuentes energéticas.
9. Industria, innovación e infraestructuras	Construir infraestructuras resilientes, promover la industrialización sostenible y fomentar la innovación.	De aquí a 2030, modernizar la infraestructura y reconvertir las industrias para que sean sostenibles, utilizando recursos con mayor eficacia y promoviendo la adopción de tecnologías.
11. Ciudades y comunidades sostenibles	Lograr que las ciudades sean más inclusivas, seguras, resilientes y sostenibles.	De aquí a 2030, asegurar el acceso de todas las personas a viviendas y servicios básicos adecuados, seguros y asequibles y mejorar los barrios marginales.
12. Producción y consumo responsables	Garantizar modalidades de consumo y producción sostenibles.	De aquí a 2030, lograr la gestión sostenible y el uso eficiente de los recursos naturales.
13. Acción por el clima	Adoptar medidas urgentes para combatir el cambio climático y sus efectos.	Incorporar medidas relativas al cambio climático en las políticas, estrategias y planes nacionales

Alcance

El presente proyecto de investigación pretende realizar el diseño de algoritmos inteligentes de predicción de generación de energía fotovoltaica basados en las siguientes técnicas de aprendizaje profundo: Long Short-Term Memory (LSTM), LSTM Projected (LSTMP), BiLSTM, Gated Recurrent Unit (GRU), Convolutional Neural Networks (CNN) e Híbrido. En primera instancia es indispensable determinar una zona aislada del Ecuador, lo cual se realizará al considerar el potencial que tiene el país para aprovechar la energía solar y el lugar donde el uso de energías renovables como fuente primaria de energía sea prioritaria. Una vez seleccionada la ubicación geográfica, se obtendrán los datos meteorológicos provistos por el sitio Photovoltaic Geographical Information System (PVGIS) proporcionados por la Unión Europea (European Commission, 2022). Posteriormente, se efectuará un estudio inicial de los datos que permita caracterizarlos, paso necesario según la teoría de predicción. Debido a que los métodos de predicción requieren que los datos posean ciertas características, es adecuado procesarlos antes de que sirvan de entrada para llevar a cabo el entrenamiento de los algoritmos. La metodología a seguir para el desarrollo se muestra en la Figura 2, la cual permite observar de forma sucinta el procedimiento general para llevar a cabo la predicción, donde las técnicas de aprendizaje profundo a diseñar y que serán sometidas a entrenamiento corresponden a LSTM, LSTMP, BiSLTM, GRU, CNN e Híbrido.

Figura 2

Diagrama de flujo para realizar la predicción



Cada método se diferencia el uno de otro en cuanto a su forma de entrenamiento, por lo que se desarrollarán diversas iteraciones o modificaciones hasta alcanzar una respuesta idónea para que puedan ser validados. Realizado el entrenamiento, la etapa de validación se realizará a través de criterios estadísticos que toman en cuenta el error de predicción tales como RMSE y MAPE. Asimismo, se obtendrá el coeficiente de correlación que servirá como indicador de cuan preciso es el método de predicción, al comparar los resultados obtenidos, se establecerá cual es el método más preciso para realizar la previsión con lo cual se podrá determinar el potencial de generación de energía en la zona del país determinada.

Finalmente, el código desarrollado para la predicción será compartido en el repositorio GitHub para que esté disponible para la comunidad científica y público en general interesado en el desarrollo y utilización de energías renovables.

Objetivos

General

Diseñar algoritmos basados en técnicas de aprendizaje profundo para la predicción de energía fotovoltaica en una zona aislada del Ecuador.

Específicos

- Caracterizar una zona aislada del Ecuador para la adquisición, análisis y procesamiento de datos.
- Diseñar los modelos aprendizaje profundo LSTM, LSTMP, BiLSTM, GRU, CNN e Híbrido para la predicción de energía fotovoltaica.
- Comparar los resultados de predicción a través de la aplicación de criterios estadísticos, para la evaluación y determinación de forma cuantitativa del mejor método de predicción.
- Compartir el código de predicción con la comunidad científica y público en general mediante su publicación en el repositorio GitHub.

Estado del Arte

A continuación, se describen brevemente las características más relevantes de modelos de predicción de generación eléctrica en sistemas fotovoltaicos publicados en la literatura científica en los últimos años.

En (Arcos-Aviles, et al., 2018) muestra una estrategia de gestión difusa basada en el pronóstico de potencia de una microrred aplicada a un escenario de microrred electrotérmica. La estrategia gestiona la energía almacenada en un sistema de almacenamiento de energía para cubrir parte de la energía requerida por el sistema de generación térmica para el suministro de agua caliente sanitaria a una residencia. Mediante la adición del pronóstico de energía se suaviza el perfil energético de la red y la evolución del Estado de Carga de la batería, es decir, reduce los valores máximos y mínimos de las fluctuaciones de energía de la

red, frente al escenario que no considera el pronóstico de energía. En (Romero, Quilumba, & Arcos, 2017) presenta un modelo de predicción a corto plazo de potencia activa basado en una ANN. Los datos corresponden a series de tiempo de variables meteorológicas, como velocidad de viento, radiación, humedad relativa, entre otras y eléctricas como la potencia. El diseño de la ANN considera la selección de variables a utilizar como las mejores entradas al modelo y un número adecuado de capas, neuronas, algoritmo de aprendizaje y función de transferencia. En (Toledo, Macancela, Aucapiña, Álvarez, & Morales, 2019) utiliza los datos de la medición de 3 años de un área rural ecuatoriana, de la comunidad Saraguro – Uchucay, para predecir la radiación solar a través del uso de análisis de datos e inteligencia artificial para determinar la incidencia de la radiación solar y establecer un modelo de producción de electricidad para satisfacer la demanda de energía eléctrica. Los trabajos descritos anteriormente no utilizan un método de optimización para la obtención de los hiperparámetros de aprendizaje, lo que implica que los modelos no han sido explotados de manera eficiente.

Según lo mencionado anteriormente, en la literatura de predicción de variables involucradas en la generación de energía eléctrica a partir de energía fotovoltaica como fuente primaria, es un tema que tiene vigencia en la investigación y tiene varias aplicaciones como se describirá posteriormente. A continuación, se presentan varios trabajos que realizaron la predicción de energía fotovoltaica en base a técnicas de DL.

En (Kumar, Mathur, Bhanot, & Bansal, 2020) se predice la irradiancia solar para analizar el comportamiento de la frecuencia de carga y la respuesta de fuentes no renovables al aumento y la caída repentina de la demanda de energía de la carga en una microrred. Se toman datos de radiación solar cada hora de Solar Pack localizado en Charanka – India durante un mes. Para predicción se utiliza una arquitectura LSTM. La red es entrenada con 90% de los datos desde el inicio del conjunto y validada con el 10% final. Se estandariza el conjunto de datos con la media y varianza para evitar divergencias y se realiza el

entrenamiento con la siguiente metodología: Solver: Adam. Capas ocultas: 200. Número de épocas: 250. Gradient threshold: 1. Initial learning rate: 0.005. Se determina la calidad de predicción del modelo LSTM, a través del criterio RMSE con un valor de 11.62, el cual se encuentra debajo de lo establecido como valor máximo de incertidumbre por la regulación de ese país. En (Wang, Liao, & Chang, 2018) presentó el método GRU para la predicción de energía fotovoltaica a corto plazo con variaciones en el procesamiento de datos para mejorar la precisión y reducir el tiempo de entrenamiento. El coeficiente de Pearson se utiliza para extraer las características principales que afectan la producción de energía fotovoltaica en el momento siguiente y analizar cualitativamente la relación entre la energía fotovoltaica histórica y la producción de energía fotovoltaica futura. En segundo lugar, se utiliza el método K-means para dividir los conjuntos de entrenamiento en varios grupos en función de las similitudes de cada característica, y luego se aplica el entrenamiento de la red GRU a cada grupo. Se promedia la salida de cada red GRU para obtener la salida de potencia fotovoltaica en el momento siguiente. Los datos utilizados corresponden a Competencia Global de Predicción Energía de 2014. La energía fotovoltaica comprende el rango de 1 de abril de 2012 al 1 de julio de 2014, en intervalos de 1 hora. Se realizó el entrenamiento con la siguiente metodología: Solver: Adam. Número de épocas: 100. Se evidenció que el tiempo de entrenamiento para GRU es menor en comparación con los demás métodos desarrollados, además, se obtuvieron menores valores de error en la predicción. En (Sodsong, Yu, & Ouyang, 2019) se desarrolló el método GRU para la predicción de energía fotovoltaica. Los datos de potencia fotovoltaica fueron obtenidos de una granja solar en Japón. La colección corresponde a los datos desde 1 diciembre de 2016 hasta 30 de noviembre de 2017, en intervalos de 5 minutos. Se utilizó la normalización para el procesamiento de datos. Se realizó el entrenamiento con la siguiente metodología: Capas ocultas: 10. Número de épocas: 20. Se obtuvieron valores bajos de error de predicción, el modelo GRU obtuvo el valor de RMSE más bajo de 9.64%, en comparación

con los demás métodos realizados, donde el RMSE obtenido fue de 10.53%, 11.62% para ANN y Vector de Regresión de Soporte respectivamente.

En (Jia, Zhang, Liu, & Gong, 2021) se desarrolló el método GRU optimizado mediante algoritmo mejorado de búsqueda de gorrión (ISSA) para la predicción a corto plazo de energía fotovoltaica. Se descompuso la serie temporal en 10 diferentes subsecuencias para reducir la no linealidad de los datos originales. El conjunto de datos corresponde a la energía fotovoltaica una planta en Australia. Se utilizó la normalización para el procesamiento de datos. En el rango de 1 de abril de 2016 a 30 de abril de 2018 cada 5 minutos. Se ajustaron los datos en intervalos de 15 minutos. El método optimizado GRU-ISSA aseguró una predicción precisa, comparado con los otros métodos desarrollados en este trabajo como el simple GRU. Se obtuvo un coeficiente de correlación mayor entre los valores reales y los pronosticados, con GRU optimizado 0.9987 frente al 0.9821 del GRU simple. En (Liu, Gao, & Pengcheng, 2021) se presentó un modelo de generación de energía fotovoltaica, en el cual se mejoró la calidad de los datos al aplicar la técnica de ontología y se utilizó el método GRU como modelo de predicción. Los datos utilizados corresponden a la generación de energía fotovoltaica del Centro Solar de Australia, en el rango de 1 de enero de 2020 a 30 de diciembre de 2020 cada 5 minutos. El algoritmo de ontología se refiere al contexto con el cual se obtienen los datos, con lo cual se provee una mejor base para los datos. A su vez, el procesamiento de datos se realiza mediante la estandarización. Se obtuvo que el método GRU es superior al LSTM en la predicción realizada en un 5% y 50% superior a los métodos de regresión lineales clásicos. En (Buturache & Stancu, 2021) presentó el modelo GRU para realizar la predicción de energía fotovoltaica. Se realizó el procedimiento estándar para la predicción. Los datos corresponden a la producción de energía con una resolución de 1 hora. Se utilizó la división de datos mediante Hold-out y se realizó el entrenamiento con la siguiente metodología: Solver: Adagrad. Capas ocultas: 2. Número de épocas: 50. Tasa de aprendizaje 0.01. Se comparó los resultados

obtenidos con el método GRU frente al LSTM, donde GRU realizó el entrenamiento en menor cantidad de tiempo y mayor precisión. En (Khan, et al., 2021) se desarrolló el método GRU de Hiperbanda para la predicción de energía, voltaje y corriente de una planta fotovoltaica. El modelo realizó una predicción de un mes con datos de 11 meses de resolución de cada día provenientes de una planta fotovoltaica en Pakistán. La obtención de los hiperparámetros óptimos se realizó a través de hiperbanda, que consiste en un proceso iterativo, donde se intentan varias configuraciones en una sola prueba y se selecciona la mejor configuración. Se realizó el entrenamiento con la siguiente metodología: Solver: Adam. Número de épocas: 150. El método GRU de hiperbanda obtuvo los valores más bajos de error en la predicción de energía fotovoltaica. El RMSE obtenido fue de 0.0395 en comparación con otros métodos tradicionales como ANN, RNN y LSTM que obtuvieron como valor de RMSE 0.1792, 0.1183 y 0.1018 respectivamente. En (Liu, et al., 2021) se propuso el método basado en la estructura SRNN, a diferencia de las RNN que actúan de forma secuencial, las SRNN añaden estructuras en paralelo para calcular de forma paralela la potencia fotovoltaica. Se obtuvieron datos de northwest power station con un intervalo de 5 minutos durante 2018. Se desarrollaron modelos además del SRNN, basados en RNN, LSTM y GRU para comparar el desempeño. Los parámetros de entrenamientos fueron los siguientes: 300 capas ocultas, como optimizador se utilizó el criterio Adam. Los resultados de los modelos se evaluaron con las métricas MAE y MSE con los cuales se obtuvieron los siguientes valores para el modelo RNN: 0.5673, 2.3149; LSTM: 0.3485, 0.6037; GRU: 0.3813 y SRNN-GRU: 0.1102, 0.1145. Se concluyó que el modelo SRNN además de obtener resultados de forma más rápida, obtuvo resultados más precisos frente a los otros modelos.

En (Sabri & El Hassouni, 2022) se desarrolló un modelo híbrido de DL, basado en GRU y CNN para el pronóstico de energía fotovoltaica a corto plazo con un intervalo de cinco minutos. En el modelo, la capa GRU es utilizada para extraer las características temporales y la

capa CNN se utiliza para extraer las características espaciales correspondientes a las características de salida. Se obtuvieron datos de Desert Knowledge Australia Solar Centre (DKASC) durante el período de mayo 2017 a mayo 2021 con una resolución de 5 minutos. Se desarrollaron modelos además del híbrido, basados en LSTM y GRU para comparar el desempeño. Se realizaron 5 diferentes test variando parámetros de entrenamiento. Un test contuvo los siguientes valores: 100 capas ocultas para GRU y LSTM, 200 filtros para CNN y 100 capas ocultas con 200 filtros para el modelo híbrido GRU-CNN. Los resultados de los modelos se evaluaron con las métricas MAE, MSE, RMSE y coeficiente de determinación, con los cuales se obtuvieron los siguientes valores para el modelo GRU: 0.0829, 0.0220, 0.1484, 0.9988; LSTM: 0.0958, 0.0446, 0.2113, 0.9977; CNN: 0.1193, 0.0493, 0.222, 0.9975 y GRU-NN: 0.0755, 0.0194, 0.1394, 0.990. Se concluyó que el modelo híbrido GRU-CNN es el que mejores resultados presentó en la tarea de predicción. En (Koprinska, Wu, & Wang, 2018) se utiliza CNN para predicción de series temporales de potencia fotovoltaica en intervalos de 30 minutos. Se comparó el desempeño del modelo CNN con LSTM. Se obtuvieron datos de Australia del 10 de enero 2015 al 31 de diciembre de 2016 de una planta localizada en la Universidad de Queenslad. Para cada día se seleccionaron datos de 10 horas durante la presencia de luz solar de 7am – 5pm. Los datos originales fueron obtenidos en intervalos de 1 minuto, pero fueron promediados para obtener valores de intervalos de 30 minutos. Para el entrenamiento de las arquitecturas CNN con 2 capas convolucionales se utilizaron (20,8) y (64,32) nodos en el primer y segunda capa respectivamente con y sin max pooling layers y el número de épocas de entrenamiento fue de 2000 y 3000. El modelo CNN se comparó con el modelo LSTM, el cual tuvo los siguientes valores de entrenamiento: 128 capas ocultas y 2000 épocas. Se comparó el desempeño de los modelos CNN con LSTM en base a las métricas MAE y RMSE donde se obtuvieron los siguientes resultados: 114.38, 153.91 y 127.67, 161.55 para CNN y LSTM respectivamente. Se concluyó que el modelo CNN fue más preciso que el

modelo LSTM. En (Suresh, Janik, Rezmer, & Leonowicz, 2019) se presentó diferentes arquitecturas de CNN con la implementación de ventana de datos deslizante para el preprocesamiento de datos para la predicción de energía fotovoltaica a corto y mediano plazo. Se comparó el desempeño de los modelos basados en CNN con modelos de regresión lineales. Se obtuvieron datos de 6 años durante el 1 de marzo de 2012 hasta 31 diciembre de 2018 en cada hora. Los parámetros de entrenamiento con el modelo de CNN fueron los siguientes: 100 épocas y un filtro de tamaño 5 para el ventaneo. Se evaluó al modelo con las métricas RMSE y MAE y se comparó los resultados con el modelo ARMA, los cuales obtuvieron los siguientes valores: 0.169, 0.169; 0.046, 0.043 para CNN y ARMA respectivamente. Se concluyó que el modelo que el modelo CNN tiene un buen desempeño en la predicción, sin embargo, el modelo ARMA es el modelo más preciso debido a que obtiene mejores valores de métricas de desempeño.

En (Wang, Qi, & Liu, 2019) se desarrollaron tres modelos de DL para la predicción de energía fotovoltaica de 1 día, CNN, LSTM y un modelo híbrido CNN-LSTM, se comparó el desempeño de los modelos en diferentes lapsos desde 0.5 años a 4 años para determinar cuál es el más preciso en la predicción. Se obtuvieron datos del sistema Alice Springs PV durante los años 2014 – 2017 con una resolución de 5 minutos. Los parámetros de entrenamiento de los métodos para 3 años fueron los siguientes: Número de épocas: 100; CNN: filtros:4096, tamaño de kernel: 3, stride: 2, dropout: 0.5; LSTM: capas ocultas:500, dropout:0.5 y CNN-LSTM: filtros: 3000, kernel: 3, stride: 2, dropout: 0.5. Se evaluaron los modelos con las métricas RMSE, MAE y MAPE, donde se obtuvieron los siguientes resultados: 0.398, 0.181, 0.032; 0.367, 0.140, 0.025; 0.343, 0.126, 0.022 para LSTM, CNN y CNN-LSTM respectivamente. Se concluyó que los tres métodos tienen un buen desempeño, pero el modelo más preciso según las métricas fue el modelo LSTM. En (Agga, Abbou, Labbadi, & El Houm, 2021) se proponen los modelos híbridos CNN-LSTM y ConvLSTM para predecir la producción de energía en una

planta fotovoltaica de 1 día. Se compararon los resultados obtenidos con el modelo LSTM. Se obtuvieron datos de una planta fotovoltaica en Marruecos entre el 21 de julio de 2019 y 31 de octubre de 2020. Para el modelo CNN-LSTM se utilizó como 20 el tamaño del filtro, 3 tamaño de kernel, relu como función de activación, capa de Max Pooling Flatten y en la componente LSTM 20 capas ocultas. En el modelo ConvLSTM se utilizó como 20 el tamaño del filtro, (1,3) tamaño de kernel, relu como función de activación y en la componente LSTM 20 capas ocultas. Como métricas para evaluación de desempeño se utilizaron RMSE, MAE y MAPE, donde se obtuvieron los siguientes valores: (6.822, 5.180, 20.805), (6.642, 5.049, 20.138) y (6.885, 5.120, 20.282) para CNN-LSTM, ConvLSTM y LSTM respectivamente. Se concluyó que los modelos híbridos fueron más precisos que el modelo simple LSTM.

Según lo mencionado anteriormente, los modelos LSTM presentan mejor desempeño en el aprendizaje de las características de las series temporales de energía fotovoltaica, al obtener menor valor de error al comparar con otros métodos de DL. Los modelos híbridos también presentan buen desempeño, pero tienen arquitecturas complejas y la precisión de predicción es similar a métodos simples como LSTM. Como métrica cuantitativa de desempeño, generalmente se utiliza la RMSE. Los modelos que utilizaron alguna técnica de optimización para la obtención de hiperparámetros presentaron un desempeño superior frente a los modelos que no incluían este proceso. Existen varios algoritmos de búsqueda de hiperparámetros óptimos, por lo cual son adaptables a diversos escenarios de predicción de energía fotovoltaica. Los modelos con hiperparámetros óptimos redujeron el costo computacional de entrenamiento y aumentaron su precisión de predicción en contraste con los modelos simples.

Capítulo II: Marco Conceptual

Energías renovables

Las energías renovables son aquellas cuyo potencial es inagotable, ya que provienen de la energía que llega a nuestro planeta de forma continua (Schallenberg & Piernavieja, 2008).

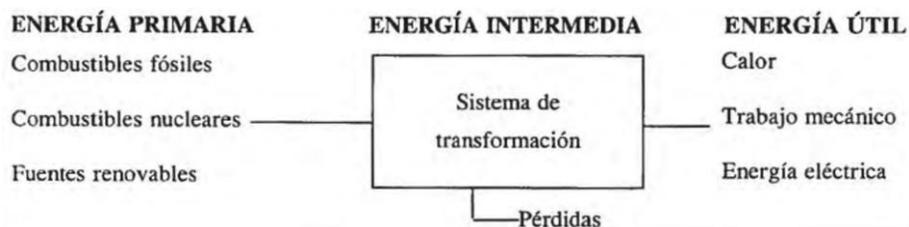
En sentido estricto, es renovable cualquier proceso que no altere el equilibrio térmico del planeta, que no genere residuos irrecuperables, y que la velocidad de su consumo no sea superior a la velocidad de regeneración de la fuente energética y de la materia prima utilizada en el mismo. (Carta González, Calero Pérez, Colmenar Santos, & Castro Gil, 2009).

El uso de energía renovables frente a convencionales contribuye a la reducción de emisiones de gases de efecto invernadero, limitando así los futuros impactos climáticos y meteorológicos extremos, y asegurando un suministro de energía confiable y rentable. Las energías renovables no incluyen los recursos energéticos derivados de combustibles fósiles, productos de desechos inorgánicos. (Ellabban, Abu-Rub, & Blaabjerg, 2014)

Desde el punto de vista de utilización de energía, se distingue a la energía renovable como una fuente de energía primaria, ya que se la obtiene directamente de la naturaleza, la cual sirve como base a la energía intermedia que a través de un sistema de transformación se convierte finalmente en energía útil que puede ser consumida. Como se muestra en la Figura 3 la transformación de energías primarias a útiles requiere de operaciones o procesos que trae consigo una pérdida de energía, debido a las tecnologías disponibles, de ahí la importancia de tratar de aumentar la eficiencia en la transformación. (Jarabo, Perez, Elortegui, Fernandez, & Macias, 1988)

Figura 3

Conversión y utilización de energía



Nota. Adaptado de *Conversión y utilización de la energía*, por F. Jarabo, 1988

A continuación, se describen algunos tipos de energías renovables:

- Hidráulica

Aquella que aprovecha los cauces y caídas de agua para generar electricidad, lo que provoca el movimiento de turbinas que, a su vez, acciona un generador, produciendo electricidad. Generalmente requieren de una gran inversión para su construcción.

- Térmica

Aquella que convierte la energía química de un combustible en energía eléctrica. Según el combustible utilizado se las denomina centrales térmicas de carbón, de fuel o de gas. Las centrales térmicas constan, en su forma más simple, de una caldera y de una turbina que mueve un generador eléctrico.

- Eólica

Se obtiene de la energía cinética generada por el viento, transformándola en mecánica o eléctrica. La energía eólica es aprovechada mediante máquinas compuestas por aspas oblicuas unidas por un eje giratorio, llamadas aerogeneradores o turbinas eólicas, que se encargan de transformar la energía del viento. A la instalación conjunta de turbinas eólicas conectadas a redes de suministro se le llama parque eólico, que puede ser *onshore* (instalados en tierra) u *offshore* (instalados en mar).

- Biomasa

Se obtiene a partir de compuestos orgánicos, producto de procesos naturales. La biomasa se forma a partir de la luz solar mediante un proceso denominado fotosíntesis vegetal, donde las plantas que contienen clorofila transforman sustancias sin valor energético en compuestos orgánicos de alta energía. Las tecnologías de generación eléctrica a partir de biomasa se clasifican en:

a) Procesos bioquímicos

Degrada la biomasa mediante microorganismos, se dividen en:

i) Procesos anaeróbicos

Basados en la descomposición de materia orgánica (como estiércol, lodos de aguas residuales, residuos urbanos sólidos o líquidos y residuos agrícolas) en biogás mediante la acción de microorganismos en ausencia de oxígeno, el biogás suele utilizarse como combustible para vehículos.

ii) Procesos aeróbicos

La materia orgánica (caña de azúcar, yuca, maíz y otros) se transforma en alcohol.

b) Procesos termoquímicos

Producen energía térmica en forma de combustibles sólidos, líquidos o gaseosos, se dividen en:

i) Combustión directa

Proceso mediante el cual el carbono (C) e hidrógeno (H) reaccionan con el oxígeno para formar CO_2 , agua y liberar calor, la energía térmica se aprovecha en usos domésticos o industriales.

ii) Pirólisis

Proceso que lleva a cabo la descomposición de la biomasa para la obtención de combustibles sólidos, como carbón vegetal, líquidos y gaseosos,

iii) Gasificación

Realiza la quema de biomasa, originando un combustible abundante en monóxido de carbono (CO) e hidrógeno llamado “gas pobre”. La gasificación es más eficiente que la combustión directa en la producción eléctrica.

- Biogás

Procedente de digestiones anaerobias de residuos agrícolas, ganaderos, industriales, lodos de aguas residuales y de vertederos, es decir, producto de la transformación de biomasa en combustible. Las aplicaciones más usuales del biogás son: calentamiento, combustión de calderas de vapor convencionales y como combustible de motores de combustión interna destinados a la generación de electricidad. (Schmerler, Velarde, Rodríguez, & Solís, 2019)

Energía solar

Es la energía que se obtiene de la captación de radiaciones electromagnéticas provenientes del sol.

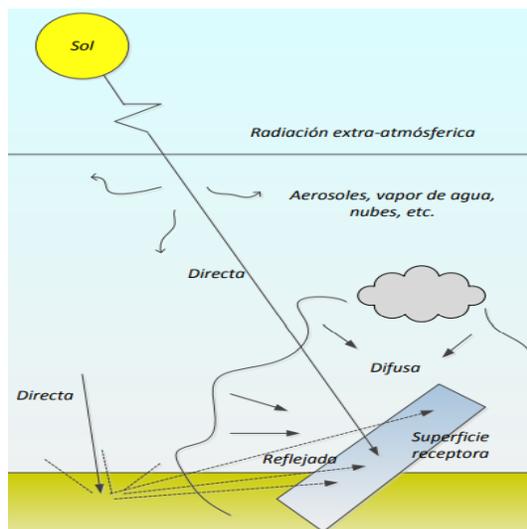
Conceptos

- Radiación

Energía electromagnética propagada o recibida, expresada en (W/m^2). La radiación solar se modifica al atravesar la atmósfera por interacción con sus componentes, como resultado la radiación solar que incide sobre un receptor situado en la superficie de la Tierra se divide en tres componentes, como indica la Figura 4:

Figura 4

Componentes de la radiación solar



Nota. Adaptado de *Distintos componentes de la radiación solar*, por M. Terreros, 2017

- Radiación directa: Constituida por los rayos recibidos en línea recta desde el Sol.
- Radiación difusa: Constituida por los rayos no directos y dispersados por la atmósfera en la dirección del receptor.
- Radiación del albedo: Procedente del suelo y debida a la radiación incidente en él y reflejada hacia el receptor

La radiación total (directa + difusa + albedo) incidente en una superficie se denomina radiación global.

- Irradiancia

Cantidad de potencia o energía electromagnética que incide o atraviesa la unidad de superficie en unidad de tiempo (W/m^2).

- Irradiancia directa total horizontal

Se refiere a la irradiancia directa total sobre un plano de inclinación β , generalmente se consideran las placas solares, se expresa como:

$$I_{\beta} = I_n \cos(i) \quad (1)$$

Donde i es el ángulo de incidencia que forman los rayos solares directos con la normal del plano receptor por el plano iluminado y I_n corresponde a la irradiancia directa total normal, valor que se obtiene de la atenuación de la radiación solar directa en la atmósfera, para cielo claro, según el modelo elaborado por Bird y Hulstom (Bird & Hulstrom, 1981).

- Irradiación

Cantidad total de energía electromagnética recibida por la superficie irradiada durante el tiempo considerado y despedida hacia el espacio. (Terreros, 2017)

Existen dos efectos que permiten la conversión de la radiación solar en energía eléctrica: el termoelectrónico y el fotoelectrónico. En el primero, la corriente eléctrica se produce a partir del calor de la radiación luminosa, mientras que, en el segundo, es la energía de los corpúsculos constituyentes de la luz (fotones) la que se aprovecha para producir electricidad. El efecto fotoelectrónico contempla la generación fotoemisiva, fotogalvánica y fotovoltaica. Debido a que las dos primeras variantes fotoeléctricas no tienen mucha aplicación, se detalla la generación fotovoltaica, la cual convierte directamente la energía solar en eléctrica, este proceso está basado en el efecto fotovoltaico. (Jarabo, Perez, Elortegui, Fernandez, & Macias, 1988)

Energía solar fotovoltaica

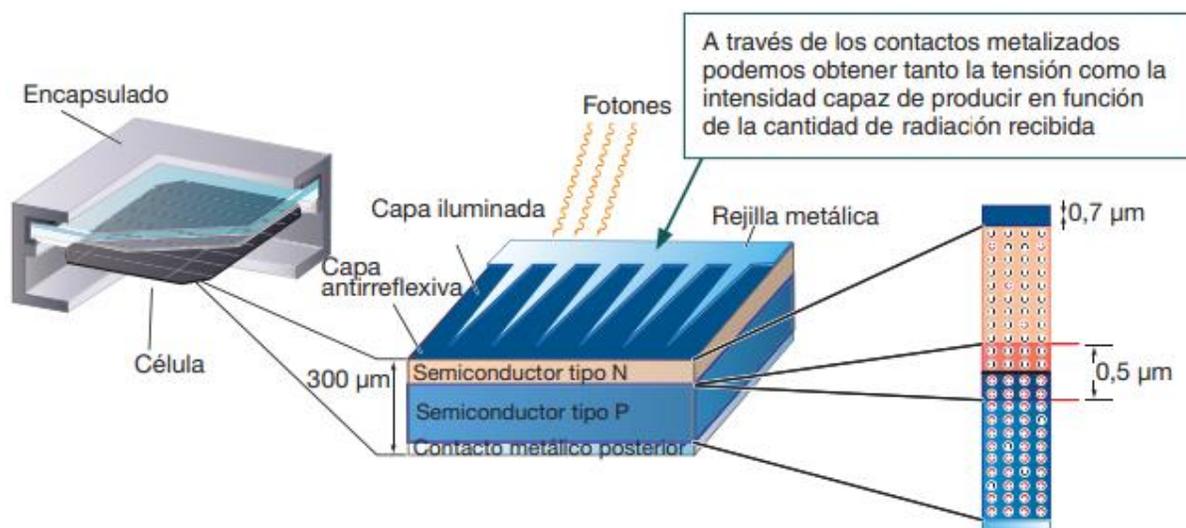
Basado en el efecto fotovoltaico, el cual consiste en la producción de una fuerza electromotriz en un material semiconductor, que está fabricada a partir del silicio, uno de los metaloides más abundantes del mundo, como consecuencia de la absorción de fotones. (Jarabo, Perez, Elortegui, Fernandez, & Macias, 1988).

En una celda fotovoltaica, cierta cantidad de radiación proveniente del Sol, en forma de fotones, es reflejada, otra parte es disipada como calor, y otra parte logra entrar en contacto con la barrera p-n del semiconductor, el impacto de tales fotones libera a los electrones más

externos (electrones de valencia) produciendo huecos o agujeros de electrones en la celda, y si entre los terminales del semiconductor se forma un circuito externo, dichos electrones pueden viajar libremente de la capa n a la capa p, generando una corriente eléctrica (Paredes, 2022), como se muestra en la Figura 5.

Figura 5

Estructura de célula solar



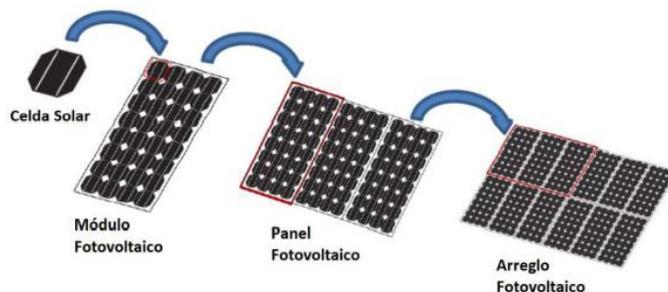
Nota. Adaptado de *Estructura de la célula solar*, por T. Díaz, 2010

Los paneles solares fotovoltaicos son un conjunto de células fotovoltaicas de iguales características que transforman la radiación solar directamente en electricidad.

Un módulo fotovoltaico incluye varias celdas solares conectadas en serie y/o paralelo (para aumentar su tensión y/o corriente). A su vez, varios módulos fotovoltaicos forman paneles, y la conexión de varios paneles constituyen un arreglo fotovoltaico, como se muestra en la Figura 6.

Figura 6

Celda solar, módulo, panel y arreglo fotovoltaico

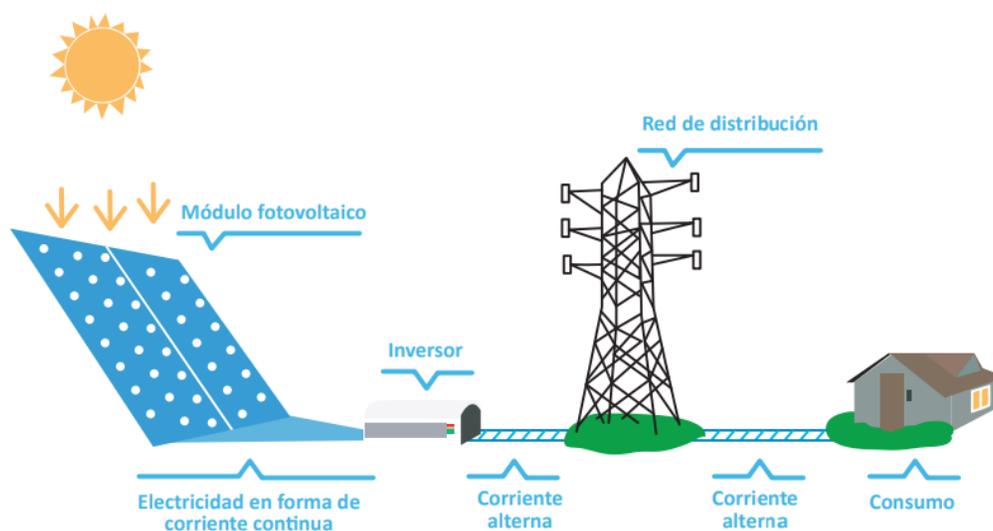


Nota. Adaptado de *Celda solar*, por E. Enríquez, 2019

Las plantas o centrales solares fotovoltaicas están constituidas por una serie de paneles fotovoltaicos conectados en serie y/o paralelo, que generan electricidad en corriente continua, la cual transforman y vierten la electricidad producida a la red eléctrica o al consumidor, este proceso se muestra en la Figura 7 (Jarabo, Perez, Elortegui, Fernandez, & Macias, 1988).

Figura 7

Formación de energía solar fotovoltaica



Nota. Adaptado de *Sistema conectado a la red*, por J. Schmerler, 2019

Ventajas del uso de energía solar fotovoltaica

- Inmenso potencial de instalación debido a su presencia en toda la superficie terrestre, lo que permite la ubicación de sistemas fotovoltaicos en cualquier parte.
- Construcción de infraestructura simple en comparación con otros sistemas de generación como el hidráulico.
- No consume combustible, no produce contaminación ambiental, es silenciosa y resistente a condiciones climáticas adversas.
- Elevada vida útil de los generadores fotovoltaicos y de mantenimiento mínimo en tiempo y costes.
- Sistemas escalables que son capaces de incrementar la capacidad de potencia instalada y ajustarse a la nueva demanda.
- Solución adecuada para suministrar electricidad a áreas rurales o remotas, aisladas de la red eléctrica principal.

Desventajas del uso de energía solar fotovoltaica

- Baja eficiencia de paneles de ciertas tecnologías.
- Generación discontinua debido a la intermitencia de la energía solar y aleatoriedad de las condiciones atmosféricas.
- Los sistemas aislados requieren de almacenamiento de energía, lo que los vuelve más caros. (Terreros, 2017)

Sistemas fotovoltaicos

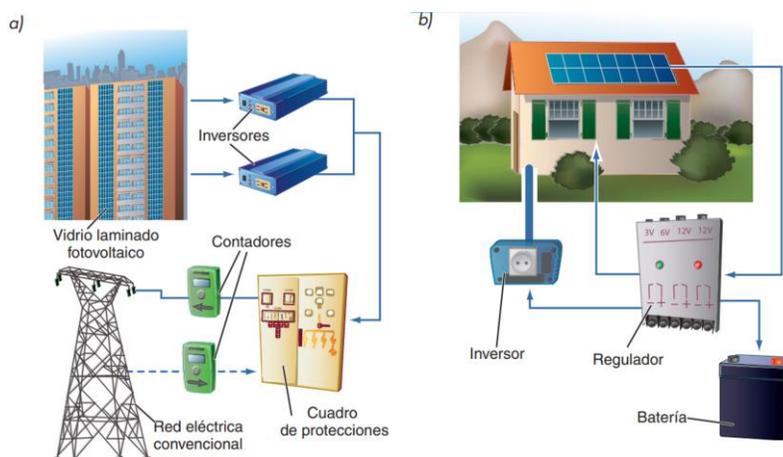
Según su aplicación, se distinguen entre aplicaciones autónomas y aplicaciones conectadas a la red, como se muestra en la Figura 8.

Las instalaciones autónomas, que se pueden realizar en cualquier lugar, están pensadas para países y regiones en desarrollo y todas aquellas zonas en que no existe acceso a la red eléctrica comercial, viviendas aisladas, aplicaciones espaciales, telecomunicaciones, señalización, alumbrado público, etc.

En las instalaciones conectadas a la red, el productor no utiliza la energía directamente, sino que es vendida al organismo encargado de la gestión de la energía del país

Figura 8

Sistemas fotovoltaicos a) Conectados a la red y b) Sistema autónomo



Nota. Adaptado de *Sistemas conectados a la red*, por T. Díaz, 2010

Componentes

De manera general, una instalación solar fotovoltaica presenta los componentes mostrados en la Figura 9, los cuales se detallan a continuación:

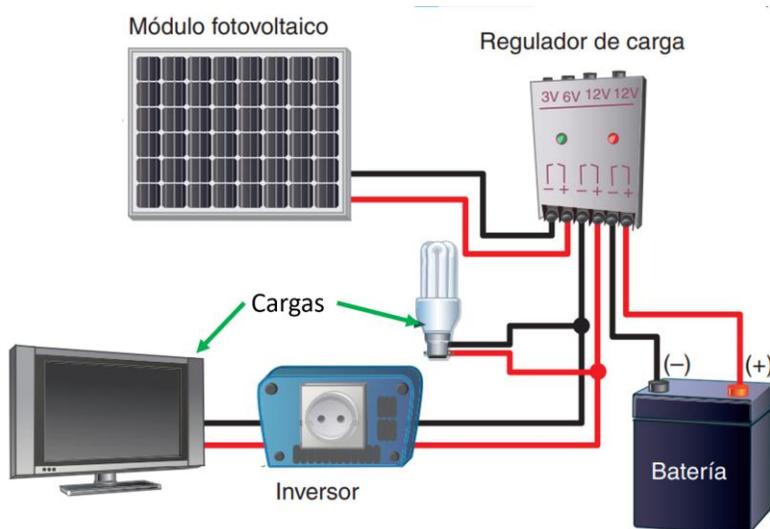
- Regulador

Nexo de unión entre los paneles solares y los elementos de consumo de la instalación. Se encarga también de proteger a los acumuladores ante sobrecargas. Proporciona a su salida la tensión continua para la instalación. Fija el valor de la tensión nominal a la que trabaja la instalación.

- Inversor
Convierte la corriente continua del sistema en corriente alterna igual a la red eléctrica. Alimenta la carga que trabaja con corriente alterna.
- Carga
Aparatos conectados a la instalación solar fotovoltaica.
- Batería
Solo presente en instalaciones autónomas. Proporciona energía a la instalación durante los períodos sin luz solar o sin suficiente luminosidad. Acumula energía para la instalación.
- Módulo fotovoltaico
Elemento primordial de la instalación. Convierte la energía del sol en energía eléctrica continua (corriente continua). Está formado por la unión de diversos paneles, para dotar a la instalación de la potencia necesaria.

Figura 9

Componentes de una instalación fotovoltaica



Nota. Adaptado de *Componentes de la instalación*, por T. Díaz, 2010

Modelo fotovoltaico

Como se mencionó anteriormente, los módulos fotovoltaicos constituyen el elemento primordial en una instalación fotovoltaica, ya que suplen de energía al sistema para cubrir la demanda.

La potencia de salida entregada por el módulo fotovoltaico depende de varios factores (como el material de construcción, temperatura, irradiancia incidente), la cual se expresa como:

$$P_{PV} = P_{STC} \frac{G(\beta, \alpha)}{G_{STC}} [1 + \gamma(T_C - T_{STC})] \quad (2)$$

Donde:

P_{STC} es la potencia de salida del módulo fotovoltaico (W) bajo condiciones estándar de prueba (STC)

$G(\beta, \alpha)$ es la irradiancia sobre el plano de los paneles (W/m^2)

G_{STC} es la irradiancia incidente bajo STC (W/m^2)

γ es el coeficiente de temperatura de potencia

T_{STC} es la temperatura bajo STC ($^{\circ}C$)

T_C es la temperatura de la celda ($^{\circ}C$), que puede expresarse como:

$$T_C = (T_a - 273) + \frac{G(\beta, \alpha)}{800} (NOCT - 20) \quad (3)$$

Donde:

T_a es la temperatura ambiente

$NOCT$ es la Temperatura de la Celda en Operación Nominal (Arcos-Aviles, et al., 2017)

Energías renovables en Ecuador

En 2021, la potencia nominal a nivel nacional fue de 8734.41 MW; de los cuales, 5308.27 MW (60.77%) corresponden a centrales con fuentes de energía renovable y 3426.14

MW (39.23%) a centrales con fuentes de energía no renovable. En la Tabla 2 se muestra la potencia de generación en el país.

Tabla 2

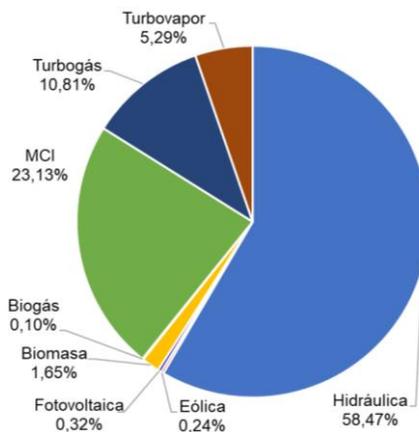
Potencia nominal de generación de fuentes renovables y no renovables

	Fuente	MW	%
Renovable	Hidráulico	5106.85	58.47
	Eólica	21.15	0.24
	Fotovoltaica	27.65	0.32
	Biomasa	144.30	1.65
	Biogás	8.32	0.10
No renovable	MCI	2020.67	23.13
	Turbogás	943.85	10.81
	Turbovapor	461.63	5.29

Como muestra la Figura 10, en Ecuador las fuentes renovables predominan en la generación de potencia, siendo la energía hidráulica la que abastece en mayor medida de energía al país, seguido de MCI de carácter no renovable (Agencia de Regulación y Control de Energía y Recursos Naturales No Renovables, 2021).

Figura 10

Generación de fuentes renovables y no renovables



Respecto a cobertura del servicio eléctrico en el país, se estimó que para el año 2018 en zonas rurales de Ecuador, no se superaría el 93.12% de acceso a electricidad, en la Figura 11 se muestra el acceso a electricidad por cada región en el país. Siendo Galápagos la provincia con el mayor indicador de acceso (Rodríguez, et al., 2021).

Figura 11

Porcentaje de acceso a electricidad en cada región en Ecuador



Nota. Adaptado de *Access to electricity in Ecuador until 2018*, por M. Rodríguez, 2021

En Ecuador, la (Agencia de Regulación y Control de Energía y Recursos Naturales no Renovables, 2021) menciona que para el año 2021 la cobertura nacional del servicio eléctrico alcanza el 97.29%. Sin embargo, dadas las condiciones geográficas del Ecuador y los altos costos asociados a la generación, transmisión y distribución de energía, aumentar la cobertura de acceso a la electricidad se vuelve un tema complejo.

Potencial de energía solar en Ecuador

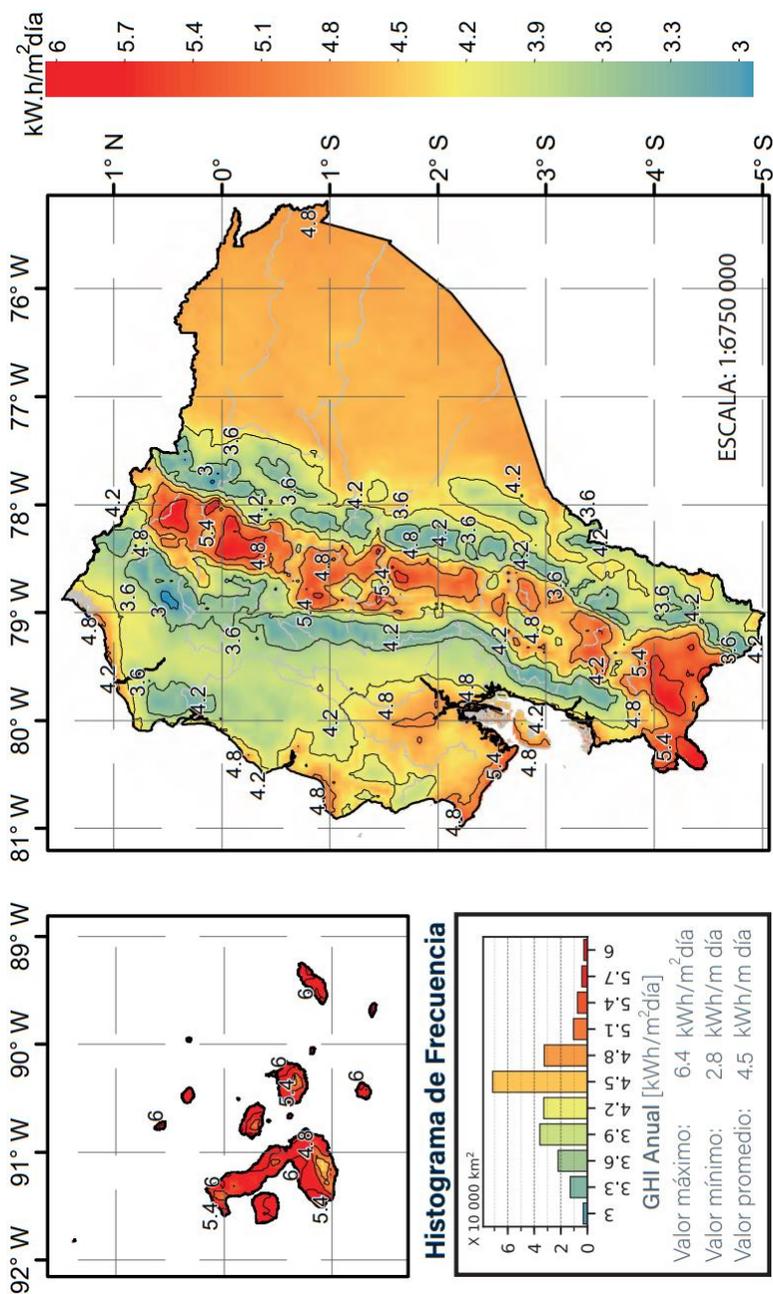
Debido a la situación geográfica del Ecuador (sobre la línea ecuatorial), el recurso solar es casi constante a lo largo del año. Esto puede representar una ventaja al evitar grandes acumulaciones de energía o equipos auxiliares sobredimensionados para cubrir la variabilidad anual del recurso. A pesar de esta ventaja, la presencia de la cordillera de los Andes crea múltiples microclimas que pueden reducir el potencial en ciertas regiones. La GHI anual sobre el Ecuador varía desde 2.9 kWh/m² día a 6.3 kWh/m² día. En general, las zonas ubicadas en elevada altitud tienen niveles de radiación mayores, mientras que las regiones de transición hacia la costa o el oriente las menores. En el primer caso, el menor espesor de la atmósfera y la menor presencia de nubes permite tener una mayor radiación. En el segundo caso, la presión atmosférica causa la formación de nubes, lo que hace de estas regiones altamente húmedas y nubosas.

Los niveles de radiación solar en Ecuador son los suficientemente altos como para amplias implementaciones de tecnologías solares térmicas y fotovoltaicas. Al tener como base el valor de 3.8 kWh/m² a partir del cual un proyecto fotovoltaico es viable. El mapa de irradiación global horizontal anual muestra que aproximadamente el 75% del territorio ecuatoriano tiene niveles de irradiación por encima de este valor. Especial atención debe darse a las provincias de Pichincha, Imbabura, Loja y Galápagos. Debido a la localización excepcional de las Islas Galápagos, su GHI es la máxima en el país, como se puede observar en la Figura 12, alcanzando valores entre 4.8 – 6.3 kWh/m² día. Esto sugiere una alta viabilidad

de implementación de tecnologías solares en la diversificación de la matriz energética de las islas. (Vaca-Revelo & Ordóñez, 2019).

Figura 12

Irradiación solar global horizontal anual en Ecuador



Nota. Adaptado de *Irradiación solar global horizontal anual en Ecuador*, por D. Vaca-Revelo, 2019

Situación energética en Galápagos

Se considera a las centrales de generación en Galápagos como sistemas aislados debido a que no están conectados al SNI. Según (Agencia de Regulación y Control de Energía y Recursos Naturales no Renovables, 2021) la cobertura del servicio eléctrico en esta provincia es del 99.46%. Según (ELECGALAPAGOS, 2021), en su informe de rendición de cuentas del año 2021, la generación y cobertura de eléctrica en la región Insular se indica en la Tabla 3. Como se puede observar, la fuente de mayor penetración está consolidada por origen térmico, siendo la de biocombustible la que tienen menor incidencia en la generación.

Tabla 3

Fuentes de generación de energía eléctrica en Galápagos

Fuente	MW	%
Térmico	21.6	70.13
Biocombustible	1.8	5.84
Eólico	4.7	15.26
Solar	4.7	8.77
Total	30.8	100

En la Figura 13 se muestra la distribución de fuentes de generación eléctrica repartidas en cada Isla, cada Isla contiene al menos una central de generación térmica, y la mayoría de centrales fotovoltaicas cuentan con sistemas de almacenamiento.

El aporte de fuentes de generación de energía a nivel provincial se muestra en la Tabla 4. Como se mencionó anteriormente, la generación eléctrica basada en fuentes térmicas abarca el 91.51% de la generación total en las Islas.

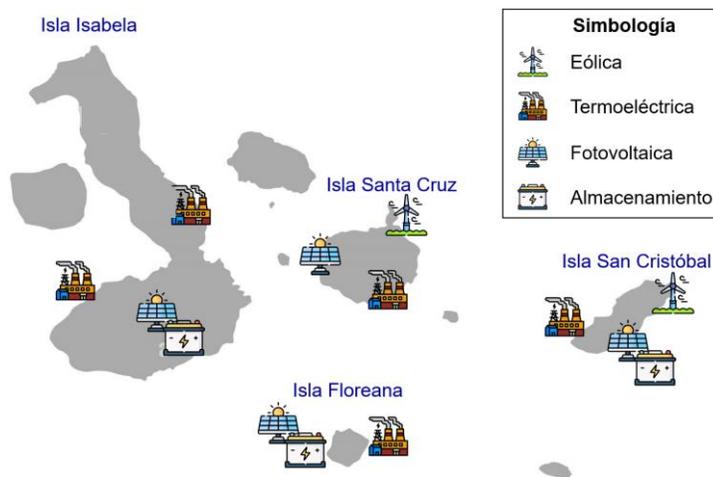
Tabla 4

Fuentes de generación de potencia eléctrica en Galápagos

Fuente	Térmico	Eólico	Fotovoltaico	Biocombustible	Total
MWH	50541.87	1951.42	2685.90	51.65	55230.84
%	91.51	3.53	4.86	0.09	100

Figura 13

Distribución de fuentes de generación eléctrica por isla



A continuación, en la Tabla 5 se muestra el aporte de fuentes de generación de energía por Isla. Cada Isla contiene al menos una central de generación fotovoltaica.

Tabla 5

Aporte de fuentes de generación por isla

Isla	Térmico %	Eólico %	Fotovoltaica %	Biocombustible %
San Cristóbal	89.71	9.13	1.15	
Isabela	73.23		26.77	
Santa Cruz	95.59	1.43	2.99	
Floreana	77.79		5.19	17.02

Según la información proporcionada por (ELECGALAPAGOS, 2021) en la provincia de Galápagos, predomina la energía térmica como fuente primaria para la generación de energía eléctrica, en contraste con las energías renovables no convencionales que no abarcan ni el 10% del total de generación, lo que repercute negativamente en el medio ambiente, por lo que es necesario aprovechar en mayor cantidad las otras fuentes para reducir el consumo de la energía térmica.

Las Islas Galápagos son Patrimonio de la Humanidad de la Humanidad debido a su extensa biodiversidad. Por ello, con la intención de evitar la degradación del hábitat y el impacto ecológico sobre el delicado equilibrio de las especies, Ecuador ha implementado la iniciativa Cero Combustibles Fósiles en Galápagos que busca sustituir el uso de combustibles fósiles. (Rodriguez, et al., 2021)

En (Rivera-González, Bolonio, Mazadiego, & Valencia-Chapi, 2019) y (Arroyo M. & Miguel, 2020) se menciona que el uso de fuentes de energía renovable incrementa la seguridad energética y permite a los países alcanzar sus objetivos de mitigación climática. El análisis de escenarios realizado menciona que depender menos de los combustibles fósiles y descentralizar el sector eléctrico del uso de termoeléctricas es el gran desafío del país. Es necesario aprovechar el enorme potencial hídrico, la energía solar, biomasa y eólica que tiene Ecuador reducirá la previsión de 60233.70 KT de CO₂ que se alcanzaría si se mantienen las condiciones de consumo energético actuales, mientras que una planificación energética a largo plazo con una mayor participación de energías renovables pronosticaría una emisión de CO₂ de 41232.30 KT, es decir, una reducción del 31.5% de las emisiones. Consecuentemente, una correcta transición energética contribuye a la protección del medio ambiente y salud pública y tiene un efecto directo en ahorro económico para el estado, lo cual beneficia al mejoramiento de la calidad de vida de los ciudadanos.

Predicción en sistemas de energía

La naturaleza intrínseca de la radiación solar y, su carácter aleatorio hace que la radiación solar que llega a la superficie de un generador fotovoltaico solo puedan ser predicciones sobre futuro, que asocian cierto grado de incertidumbre. (Terrerros, 2017)

Pronóstico en el despacho de energía renovable

Las estrategias en el despacho basadas en pronóstico son muy efectivas para reducir los costos de funcionamiento de una microrred que incluyan múltiples unidades de generación distribuida. Estos esquemas también se pueden utilizar en forma conjunta en varios aspectos operativos y económicos de un sistema eléctrico. Sin previsión de energía, el sistema experimentaría un compromiso excesivo de generación, así como una reducción mucho mayor, lo que conduciría a un aumento en los costos netos de generación. Sin embargo, la inclusión de pronósticos de energía reduce los costos netos de generación hasta cierto punto. Para un sistema solar fotovoltaico, la mejora de las previsiones tiene un valor económico anual, ya que reduce los costes operativos generales de generación de electricidad. Los pronósticos mejorados, si se incorporan adecuadamente en un algoritmo de control de despacho, pueden mejorar el rendimiento y la vida útil del sistema de almacenamiento de baterías.

Pronóstico en el dimensionamiento de sistemas de energía

Con el conocimiento de las condiciones previstas, se puede realizar un dimensionamiento optimizado del almacenamiento con un límite de incertidumbre bien definido, reduciendo simultáneamente potencia y capacidad energética. La correlación entre los errores de pronóstico es un factor importante, e ignorar la correlación puede llevar a una estimación errónea significativa de la capacidad nominal de energía y potencia del sistema de almacenamiento de energía. Las estrategias basadas en pronóstico pueden mejorar la participación de la generación de energía renovable mediante el dimensionamiento adecuado de los componentes de la microrred.

Pronóstico y mercados energéticos

Un pronóstico preciso puede mejorar los precios de la electricidad, pero depende de la penetración de energía renovable. Además, los pronósticos precisos no solo provocan reducciones significativas en las penalizaciones, sino que sus beneficios se extienden también a otras áreas, como la programación de operaciones y mantenimiento. El análisis en profundidad de las incertidumbres en términos de factores de mercado está dando nuevas direcciones para mejorar las prácticas comerciales e incluso para diseñar mejores y rentables políticas de mercado energético. La incertidumbre en la predicción de la producción de energía de una fuente de energía renovable tiene una influencia notable en los precios de mercado, en la medida en que la información precisa de los pronósticos se puede utilizar para diseñar mejores políticas de mercado de energía y más lucrativas. Los participantes con sistemas de pronóstico más precisos ciertamente maximizan sus ganancias y reducen sus pérdidas, lo que eventualmente beneficia a la sociedad en general.

Pronóstico y dimensionamiento de reservas

El pronóstico de energía fotovoltaica robusta mejora la confiabilidad del sistema de energía. La previsión precisa de la producción de energía renovable también juega un papel importante en la determinación del tamaño óptimo de la reserva necesaria para el funcionamiento fiable de una microrred con alta penetración de energía renovable. Al utilizar la información de la previsión de potencia, cortes de generación convencional e incertidumbre de las previsiones de carga, los operadores del sistema pueden definir índices de riesgo que ayuden a determinar las necesidades de reserva operativa para mercados competitivos (Ahmed & Khalid, 2019).

Importancia de acceso a energía

El Índice de Desarrollo Humano (IDH) y el consumo de energía eléctrica (per cápita) están estrechamente relacionados con el acceso de un país a la electricidad. Para aumentar el

IDH de un país, la cobertura de energía eléctrica se convierte en una prioridad crucial de preocupación mundial para promover una vida larga, saludable y digna (Shyu, 2019).

Técnicas de predicción

Adicionalmente a la clasificación descrita en los antecedentes del presente trabajo, las técnicas de predicción pueden clasificarse según el horizonte de predicción.

Horizontes de predicción

Diversos horizontes de tiempo son importantes para realizar predicciones para diferentes aspectos de operación de la red, como el mantenimiento de estabilidad de la red, cronograma de rotación de reservas, etc. Generalmente, puede ser clasificada en cuatro categorías descritas a continuación:

- Predicción a largo plazo: (1 a 10 años en adelante)

Usado para la planificación del sistema de energía, dado que esta categoría de planificación puede ayudar con la planificación de producción de energía, transmisión y distribución, de acuerdo con la demanda futura de energía.

- Predicción a medio plazo: (1 mes a 1 año)

Usada para la operación eficiente y mantenimiento del sistema de energía a través de la predicción de la disponibilidad futura de la potencia eléctrica.

- Predicción a corto plazo: (1 hora o 1 día o 1 semana en adelante)

Tiene una parte crucial en el control de reserva y la evaluación de contratos de compraventa entre varias empresas. Además, la predicción a corto plazo mejora la seguridad de operación de la red y es útil en el diseño de sistemas de gestión de energía fotovoltaica integrada.

- Predicción a muy corto plazo: (1 minuto a muchos en adelante)

También conocida como dentro de la hora o predicción inmediata, es usada para el suavizado de energía, despacho de electricidad en tiempo real y reservas óptimas para asegurar la calidad y estabilidad de la red (Konstantinou, Peratikou, & Charalambides, 2021).

Técnicas de aprendizaje basadas en aprendizaje profundo

Redes neuronales recurrentes

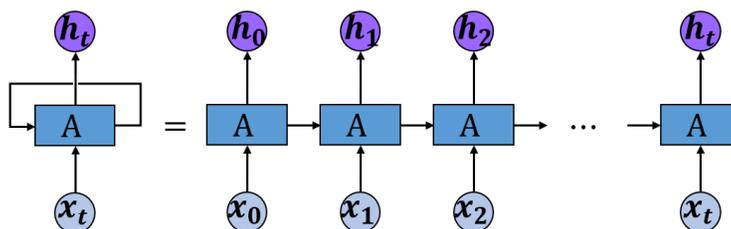
Partiendo de que los humanos no comienzan su pensamiento desde cero cada segundo. A medida que lee, comprende cada palabra en función de su comprensión de las palabras anteriores. No se empieza a pensar en cada palabra desde cero, es decir, los pensamientos tienen persistencia. Las redes neuronales tradicionales no poseen esta característica.

Las redes neuronales recurrentes abordan este problema. Son redes con bucles en ellas, lo que permite que la información persista. Según la Figura 14, un trozo de red neuronal A , tiene una entrada x_t y genera un valor h_t . El estado oculto h_t se calcula en función de la entrada en el paso actual t y el estado previamente oculto o la información del último nodo h_{t-1} en el paso $t - 1$. El bucle permite que la información pase de un paso de la red al siguiente. Se puede considerar una red neuronal recurrente como múltiples copias de la misma red, cada una de las cuales pasa un mensaje a un sucesor. El modelo matemático se expresa de la siguiente manera:

$$h_t = \sigma(h_{t-1}, x_t) \quad (4)$$

Figura 14

Redes neuronales recurrentes

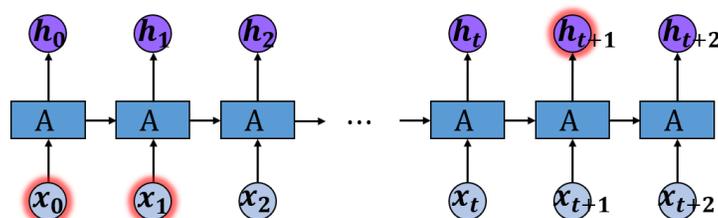


Nota. Adaptado de *Recurrent neural networks*, por C. Olah, 2015

Uno de los atractivos de las RNN es la idea de que pueden conectar información previa con la tarea actual, como se muestra en la Figura 15, sin embargo, existe una brecha entre la información relevante y el lugar donde se necesita, a medida que crece esa brecha, las RNN se vuelven incapaces de aprender a conectar la información.

Figura 15

Conexión de información en RNN



Nota. Adaptado de *Information connection of a rnn*, por C. Olah, 2015

Redes Memoria de corto-largo plazo

Las redes de memoria de corto-plazo (LSTM) son un tipo especial de RNN, capaces de aprender dependencias a largo plazo. Fueron introducidas en 1997 y desde entonces han sido refinadas y popularizadas en diversos trabajos. (Olah, 2015)

LSTM es un tipo particular de RNN. La idea principal detrás de LSTM es controlar mejor el flujo de gradiente, superando el problema del gradiente de fuga de RNN y asegurando una mejor preservación de las dependencias a largo plazo mediante el filtrado de información

redundante o engañosa. LSTM realiza esta acción gracias a una celda de memoria. Además, cada unidad LSTM trabaja en conjunto, a diferencia de RNN, que tiene solo una capa oculta. El modelo LSTM se muestra en la Figura 16. Las funciones LSTM se expresan de la siguiente manera:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (7)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (8)$$

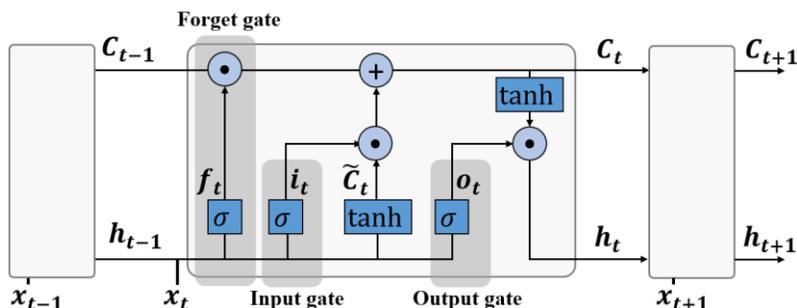
$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t * \tanh(C_t) \quad (10)$$

Donde W_f , W_i , W_C y W_o son los pesos y b_f , b_i , b_C y b_o son los vectores de parámetros de sesgo del LSTM, que se han aprendido a través de la retropropagación. Cada valor de salida de la función sigmoidea (σ) está en el intervalo entre [0-1], donde 0 significa la eliminación completa de la información y 1 significa su retención total. Además, x_t es la entrada actual en el tiempo t , que integra las cargas históricas y h_{t-1} . El vector de salida $y_t = g(h_t)$ es el valor de salida en el tiempo t , donde g puede ser cualquier función de activación. La puerta de olvido, f_t , decide qué información retener o rechazar. Con la ayuda de la puerta de entrada (i_t) y la celda de memoria candidata \tilde{C}_t , se toma la decisión de identificar qué valores actualizar o almacenar en la nueva celda de memoria C_t . La salida se calcula utilizando las expresiones anteriores. Finalmente, este proceso continúa y se repite (Chitalia, Pipattanasomporn, Garg, & Rahman, 2020).

Figura 16

Modelo de la red Long Short-Term Memory



LSTM Projectado

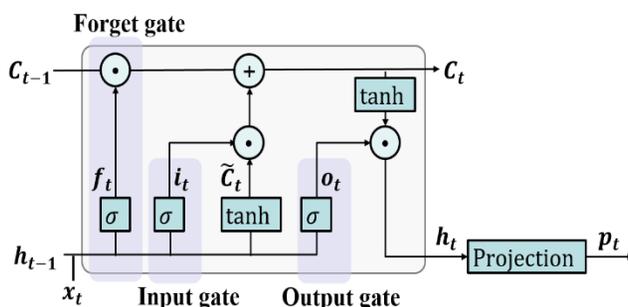
En LSTM, hay un gran número de cálculos en varias compuertas que conforman la red neuronal. Al incrementar el número de celdas de memorias se aumenta en gran medida el costo de memoria, pero si se quiere evitar esta situación al preservar un bajo número de celdas de memoria se tiene un bajo desempeño de la red neuronal. De aquí parte la arquitectura llamada LSTMP, la cual no sólo mejora la precisión del modelo, sino que también reduce efectivamente la carga computacional (Jia, Wu, Xu, Ke, & Su, 2017).

Una LSTM con capa proyectada aprende las dependencias a largo plazo entre los pasos de tiempo en las series temporales y los datos de secuencia utilizando pesos de aprendizaje proyectados. Las capas proyectadas se utilizan para comprimir una red de aprendizaje profundo. Una capa proyectada es un tipo de capa de aprendizaje profundo que permite la compresión al reducir la cantidad de parámetros de aprendizaje almacenados. La capa introduce matrices de proyección aprendibles Q , que reemplazan las multiplicaciones de la forma Wx , donde W es la matriz aprendible, con la multiplicación $WQQ^T x$, y almacena Q y $W' = WQ$ en lugar de almacenar W . Al proyectar x en un espacio de menor dimensión usando Q generalmente requiere menos memoria para almacenar los parámetros que se pueden aprender y puede tener una precisión de predicción igualmente sólida.

Al reducir la cantidad de parámetros que se pueden aprender mediante la cantidad de unidades ocultas de la capa LSTM mantiene el tamaño de salida de la capa y, a su vez, los tamaños de las capas posteriores, lo que puede resultar en una mejor precisión de predicción. (The MathWorks Inc, 2022)

Figura 17

Modelo de la red Long Short-Term Memory Projectado

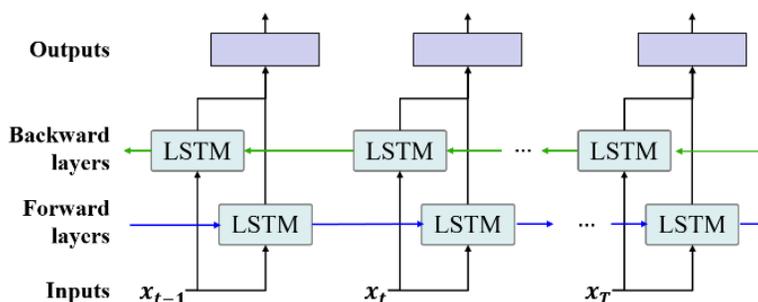


LSTM Bidireccional

El LSTM bidireccional es una extensión del modelo LSTM en el que se aplican dos LSTM a los datos de entrada. Primero, se usa un LSTM en la secuencia de entrada (capa de avance). En segundo lugar, la forma inversa de los datos de entrada se introduce en el modelo LSTM (capa hacia atrás). Aplicar el LSTM dos veces mejora el aprendizaje de las dependencias a largo plazo y, por lo tanto, mejora la precisión del modelo. Asimismo, se requiere un mayor tiempo de entrenamiento. El modelo Bi LSTM se muestra en la Figura 18.

Figura 18

Modelo de la red Long Short-Term Memory Bidireccional



Gated Recurrent Unit

El modelo GRU es bastante similar al modelo LSTM. Sin embargo, tiene la ventaja de reducir la carga computacional ya que solo utiliza dos puertas correspondientes a la puerta de reinicio y la puerta de actualización. La puerta de actualización tiene la misma funcionalidad que la puerta de reinicio en un LSTM, y decide si la información es útil o no. Además, la puerta de reinicio se utiliza para determinar si la información se guardará o eliminará (Massaoudi, et al., 2019). El modelo GRU se muestra en la Figura 19. Las funciones GRU se expresan de la siguiente manera:

$$r_t = \sigma(W_r[h_{t-1}, x_t]) \quad (11)$$

$$z_t = \sigma(W_z[h_{t-1}, x_t]) \quad (12)$$

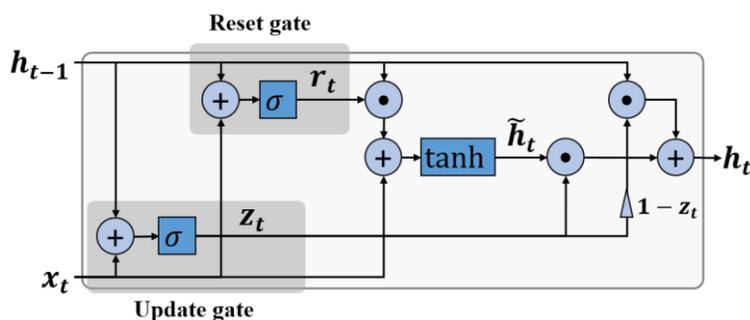
$$\tilde{h}_t = \tanh(W[r_t \cdot h_{t-1}, x_t]) \quad (13)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (14)$$

Donde z_t es la puerta de actualización, principalmente para olvidar y memorizar, r_t es la puerta de reinicio utilizada para determinar si combinar el estado actual con la información anterior, y es el estado oculto candidato calculado con r_t , x_t y h_{t-1} . Además, W_z y W_r son los pesos de conexión de la puerta de actualización y la puerta de reinicio, respectivamente, y es la función de activación.

Figura 19

Modelo de la red Gated Recurrent Unit



Redes neuronales convolucionales

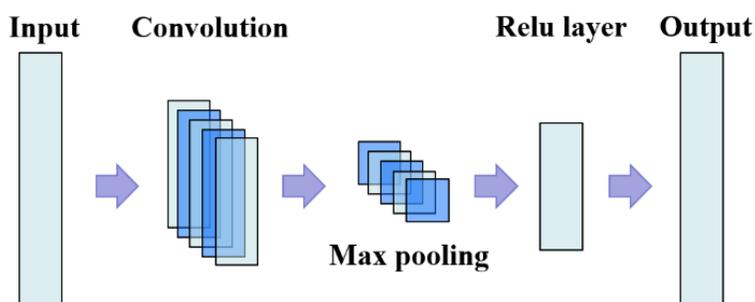
Una CNN incluye dos tipos principales de capas: convolución y max pooling. Cada capa convolucionaria la entrada con una matriz de peso con un tamaño preespecificado, llamado filtro, que define la cantidad de nodos que comparten pesos para calcular un mapa de características. Esto se logra deslizando la matriz de pesos sobre la entrada y calculando el producto escalar entre la entrada y la matriz de pesos. El modelo CNN se muestra en la Figura 20. Se considera la entrada x_m como la producción de energía fotovoltaica y n es el número de unidades por ventana. La ecuación (15) es la salida del vector y de la primera capa convolucional, donde w es el peso del kernel, m es el índice del valor del filtro.

$$y = \sigma \left(b + \sum_{m=1}^M w_m x_m \right) \quad (15)$$

La capa de agrupación máxima calcula el valor máximo de la agrupación seleccionada de neuronas adyacentes de la capa convolucional. La combinación de una capa de agrupación máxima y convolucional garantiza que la salida de la capa de agrupación máxima sea invariable a los cambios en los datos de entrada, lo cual es una propiedad beneficiosa para el procesamiento de datos de series temporales. Finalmente, la función de activación de la Unidad Lineal Rectificada (ReLU) se utiliza para calcular la predicción final (Koprinska, Wu, & Wang, 2018).

Figura 20

Modelo de la red Convolucional

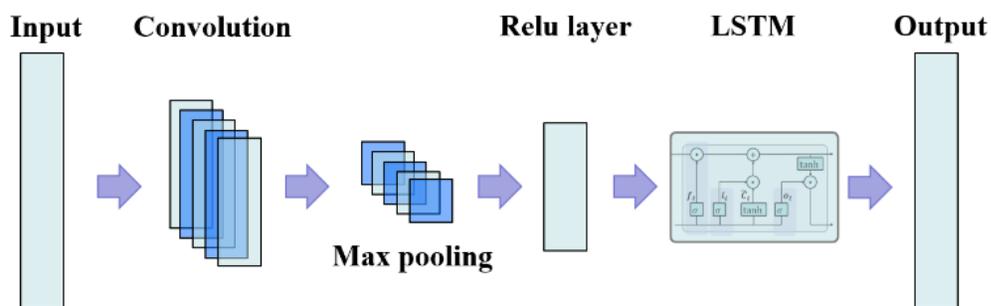


Modelos híbridos de aprendizaje profundo

La arquitectura híbrida utiliza las capas CNN descritas anteriormente para la extracción de características en los datos de entrada y se combina con un modelo basado en RNN para respaldar la predicción de secuencias. En este trabajo, el modelo RNN corresponde a LSTM. Específicamente, CNN extrae las características de las entradas y las usa en la arquitectura LSTM para generar la captura (Rajagukguk, Ramadhan, & Lee, 2020). El modelo híbrido se muestra en la Figura 21.

Figura 21

Modelo de la red Híbrida



Hiperparámetros de aprendizaje

- Optimizador

Optimizadores son algoritmos o métodos usados para cambiar los atributos de la red neuronal como los pesos y la tasa de aprendizaje para reducir las pérdidas y proveer los resultados más precisos posibles. Existen varios métodos de optimización, a continuación, se describen algunos de ellos:

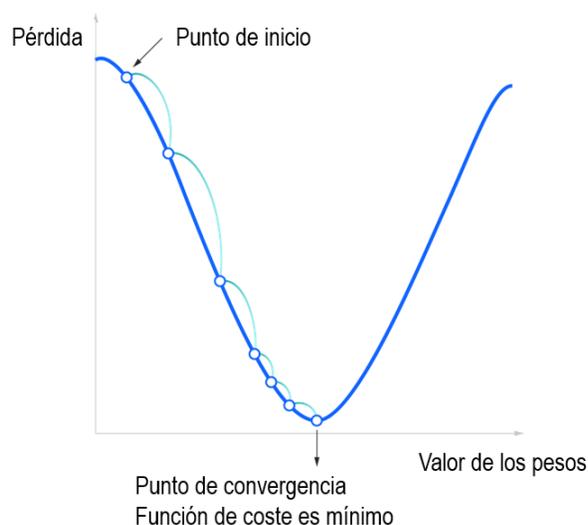
- Descenso de gradiente (GD)

También llamada steepest descent, es uno de los algoritmos de optimización de primer orden más básicos, el cual es dependiente de la derivada de primer orden de la función de pérdida. Calcula la forma en que los pesos deberían ser alterados para que la función alcance su mínimo. A través de BP, la pérdida es transferida desde una capa a otra y los parámetros

del modelo o pesos son modificados dependiendo de las pérdidas, por lo que la pérdida puede ser minimizada. Como muestra la Figura 22, el punto de partida es escogido de forma arbitraria para evaluar el desempeño, a partir de este se calcula la derivada y a partir del resultado a través de la línea tangente se observa la inclinación de la pendiente. La pendiente informará las actualizaciones de los parámetros como los pesos. La pendiente al punto de inicio será más pronunciada, pero según nuevos parámetros sean generados, la inclinación irá gradualmente disminuyendo hasta alcanzar el punto más bajo de la curva, conocido como punto de convergencia. El objetivo de GD es minimizar la función de coste, o el error entre los valores predichos con los actuales o medidos

Figura 22

Función de pérdida en Descenso de gradiente



Nota. Adaptado de *Steepest descent*, por IBM, 2020

- Descenso de gradiente estocástico (SGD)

Corre una época de entrenamiento para ejemplo dentro del conjunto de datos y actualiza los parámetros década ejemplo de entrenamiento uno a la vez. Dado que solo necesita mantener un ejemplo de entrenamiento, son más fáciles de almacenar en memoria. Si

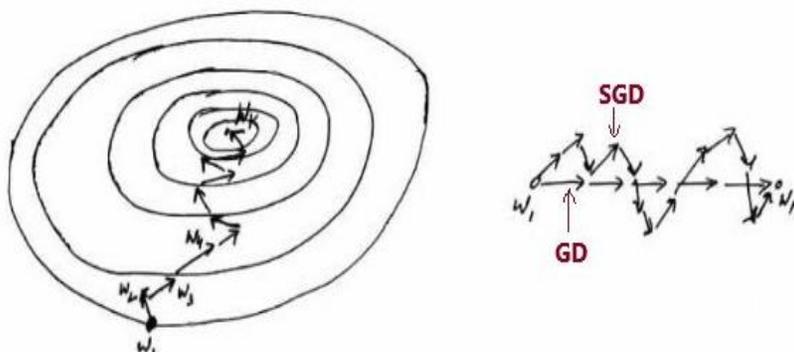
bien estas actualizaciones frecuentes pueden ofrecer más detalles y velocidad, pueden provocar pérdidas en la eficacia computacional. Las actualizaciones frecuentes pueden resultar en gradientes con ruido, pero esto puede también ser útil en escapar del mínimo local y encontrar el global. Como se puede observar en la Figura 23 las actualizaciones pueden tomar un mayor número de iteraciones comparado con GD hasta alcanzar el mínimo.

- Gradiente adaptativo (AdaGrad)

Con los algoritmos anteriores la tasa de aprendizaje se mantiene constante. La idea principal de AdaGrad es tener una tasa de aprendizaje adaptativa para cada peso. La tasa de aprendizaje para los pesos irá decreciendo con el número de iteraciones.

Figura 23

Función de pérdida en Descenso de gradiente estocástico



Nota. Adaptado de *AdaGrad*, por IBM, 2020

- AdaDelta

El problema con el algoritmo anterior AdaGrad era que la tasa de aprendizaje es muy pequeña con un número grande de iteraciones lo que conlleva a una convergencia lenta. Para evitar esto, el algoritmo AdaDelta tiene un promedio decreciente exponencial.

- Propagación de raíz cuadrática media (RMSProp)

Es una extensión de GD y AdaGrad que utiliza un promedio decreciente de gradientes parciales en la adaptación del tamaño de paso para cada parámetro. El uso de un promedio móvil decreciente permite que el algoritmo olvide los gradientes iniciales y se concentre en los gradientes parciales observados más recientemente durante el progreso de la búsqueda, superando la limitación de AdaGrad.

- Adam

Es un método eficiente de optimización estocástica que solo requiere gradiente de primer orden con requerimiento bajo de memoria. El método calcula tasas de aprendizaje adaptativas individuales para parámetros diferentes desde momentos estimados de primer y segundo orden de los gradientes. Derivado de estimación de momento adaptativo usa una actualización de parámetros que es similar a RMSProp, pero con un término de momento añadido. Mantiene una media móvil a nivel de elemento tanto de los gradientes de parámetros como de sus valores cuadrados,

$$m_l = \beta_1 m_{l-1} + (1 - \beta_1) \nabla E(\theta_l) \quad (16)$$

$$v_l = \beta_2 v_{l-1} + (1 - \beta_2) [\nabla E(\theta_l)]^2 \quad (17)$$

Donde l es el número de iteración, θ es el vector de parámetros, $E(\theta)$ es la función de pérdida, $\nabla E(\theta)$ gradiente de la función de pérdida, β es la tasa de decaimiento de la media móvil y v es el bias de inicialización.

Adam usa las medias móviles para actualizar los parámetros de la red como:

$$\theta_{l+1} = \theta_l - \frac{\alpha m_l}{\sqrt{v_l} + \epsilon} \quad (18)$$

Donde $\alpha > 0$ es la tasa de aprendizaje, ϵ constante pequeña para evitar la división entre cero y m es el bias de inicialización.

Si los gradientes a lo largo de varias iteraciones son similares, utilizar una media móvil del gradiente permite a las actualizaciones de parámetros coger impulso en una determinada dimensión. Si los gradientes contienen principalmente ruido, la media móvil del gradiente se reduce, por lo que las actualizaciones de parámetros también se reducen (Kingma & Ba, 2015).

Adam es considerado como el mejor algoritmo entre los mencionados anteriormente en tareas de ML.

- Capas ocultas

Es una capa ubicada entre la entrada y salida del algoritmo, en el cual la función aplica pesos a las entradas y las dirige a través de la función de activación como la salida. En breve, las capas ocultas llevan a cabo transformaciones no lineales a las entradas que ingresaron a la red.

- Número de épocas

Una época es un solo ciclo sobre el conjunto entero de datos. Donde cada ciclo está compuesto de varias iteraciones. Al final de una época, se requiere medir que tan bien nuestro modelo está generalizando. Para hacer esto, se utiliza el conjunto adicional de validación. Al final de cada época, el conjunto de validación nos dirá como el modelo se comporta con datos que todavía no ha visto. Si la precisión en el conjunto de entrenamiento continúa incrementando mientras que la precisión en el conjunto de validación se mantiene o decreciente, es una buena señal de que es necesario detener el entrenamiento para evitar el sobreajuste.

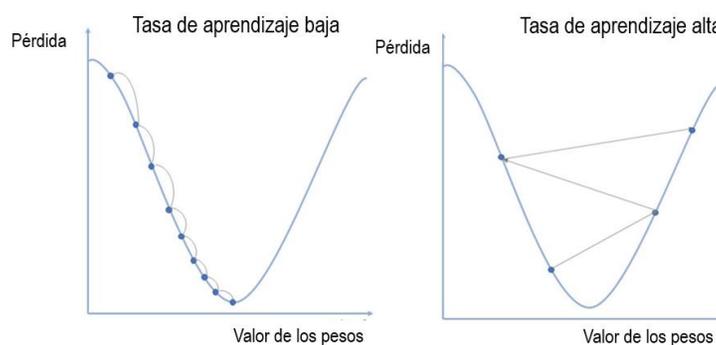
- Tasa de aprendizaje

Es el tamaño de pasos que son tomados hasta alcanzar el mínimo. Este valor es típicamente pequeño, el cual es evaluado y actualizado basado en el comportamiento de la función de coste. Tasas de aprendizaje altas resultan en grandes pasos, pero corren el riesgo de sobrepasar el mínimo. Por el contrario, una tasa de aprendizaje baja tiene pasos pequeños

como se puede observar en la Figura 24, mientras que se tiene la ventaja de mayor precisión, el número de iteraciones compromete la eficacia general, ya que requiere más tiempo y cálculos para alcanzar el mínimo.

Figura 24

Tasa de aprendizaje



Nota. Adaptado de *Learning rate*, por IBM, 2020

- Gradiente que se desvanece

Esto ocurre cuando el gradiente es muy pequeño. Debido a que el modelo se mueve hacia atrás durante BP, el gradiente continúa haciéndose más pequeño, lo que provoca que las capas en la red aprendan más lentamente que las capas posteriores. Cuando esto ocurre, los parámetros se actualizan hasta que se vuelven insignificantes lo que provoca que el algoritmo no aprenda.

- Gradiente explosivo

Esto ocurre cuando el gradiente es demasiado grande, lo que crea un modelo inestable. En este caso, los pesos de los modelos crecerán demasiado y eventualmente serán valores numéricos no válidos.

- Función de pérdida

Mide la diferencia o error, entre el valor actual o medido con el predicho. Esto mejora la eficacia del modelo de ML al proveer retroalimentación al modelo por lo que puede ajustar los

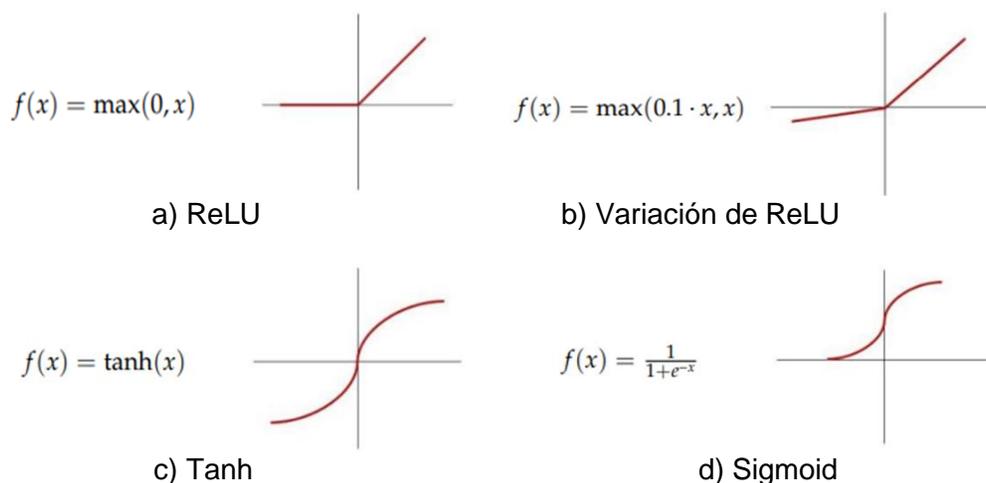
parámetros para minimizar el error o el mínimo global. Se itera de forma continua, se mueve en dirección al optimizador hasta que la función de coste es cercana o alcanza el valor de cero. En este punto, el modelo detendrá el aprendizaje (IBM Cloud Education, 2020).

Funciones de activación

El valor de salida de las redes neuronales varía con la función de activación. La función de activación, también conocida como función de transferencia, es una ecuación matemática que determina la salida de las neuronas y se puede dividir en dos tipos, a saber, funciones lineales y no lineales. Una función de activación lineal genera el mismo resultado lineal entre las capas de entrada y salida. Sin embargo, tal relación lineal no es suficiente para aplicaciones prácticas porque los problemas involucran información compleja y varios parámetros. Una red neuronal con una función de activación no lineal puede abordar las limitaciones de la función de activación lineal. Las funciones de activación comúnmente utilizadas se muestran en la Figura 25 (Rajagukguk, Ramadhan, & Lee, 2020).

Figura 25

Funciones de activación de redes neuronales



Nota. Adaptado de *Activation functions of the neural network*, por R. Rajagukguk, 2020

Optimización de hiperparámetros

El proceso de optimización se refiere a encontrar un máximo o un mínimo de la función objetivo con un determinado conjunto de combinación de parámetros.

Optimización Bayesiana

Es un enfoque basado en un modelo probabilístico para encontrar el mínimo de cualquier función que devuelva una métrica de valor real. Esta función puede ser tan simple como $f(x) = x^2$, o puede ser tan compleja como el error de validación de una red neuronal profunda con respecto a cientos de opciones de arquitectura de modelos e hiperparámetros.

Los pasos que sigue el algoritmo se describen a continuación:

1. Comienza muestreando valores aleatorios para los hiperparámetros.
2. Observa la salida que se genera (rendimiento del modelo).
3. Basado en esas observaciones, se ajusta a un proceso gaussiano.
4. Utiliza la media de este proceso gaussiano como una aproximación de la función que se desconoce.
5. Para comprender qué hiperparámetros deben muestrearse a continuación, utiliza una función de adquisición. La función de adquisición también define cuánto debe explorar el algoritmo el espacio de hiperparámetros o explotar las áreas conocidas.
6. Vuelva a ajustar el modelo y observe la salida e itere sobre el mismo proceso hasta alcanzar el número máximo de iteraciones.

Este método utiliza información de la ejecución anterior para informar las siguientes.

Esta es una herramienta muy poderosa porque nos permite reducir la búsqueda de hiperparámetros a lo largo del proceso para enfocarnos principalmente en áreas muy rentables del rango de hiperparámetros.

En términos más generales, la optimización bayesiana se puede utilizar cada vez que necesite optimizar sobre una función de caja negra. Esto significa que puede usar este método

para buscar los óptimos globales sobre cualquier función de la que pueda observar solo la entrada y la salida (Cavazza, 2021).

Adicionalmente, los autores en (Zhang, Ma, Hua, Saha, & Zhou, 2020) presentan una correlación de análisis espacio-temporal entre los datos de generación fotovoltaica del sistema fotovoltaico distribuido. Se desarrolla un modelo de inferencia basado en datos, construido sobre una red bayesiana, para un pronóstico de generación fotovoltaica a muy corto plazo. La metodología propuesta demostró que los modelos podrían entrenarse con solo un conjunto de datos para conjuntos de datos similares y presentar un error bajo en la predicción evaluada en otro conjunto de datos.

Hold out para optimización

En el método hold-out, el conjunto de datos es partido en tres diferentes conjuntos: entrenamiento, validación y prueba. Al usar el método hold-out es importante dar a cada conjunto de datos una parte representativa del conjunto de datos total, caso contrario, el modelo tendría un desempeño pobre en datos no vistos anteriormente.

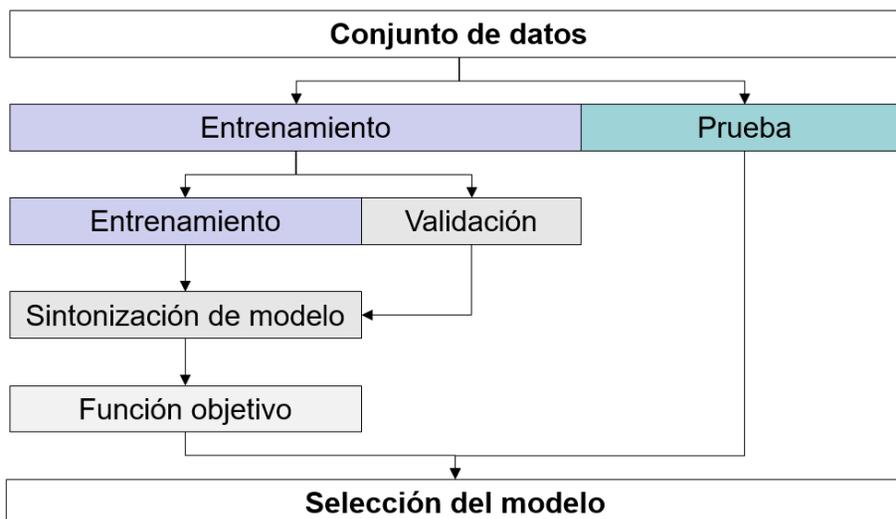
La Figura 26 muestra el proceso a seguir para la sintonización de hiperparámetros de los modelos de DL, los pasos se detallan a continuación:

1. Dividir el conjunto de datos en tres partes: Entrenamiento, validación y prueba.
2. Entrenar el modelo de forma iterativa con variación de hiperparámetros.
3. Evaluar según función objetiva los resultados de los modelos con diferentes hiperparámetros.
4. Evaluar el modelo final con todo el conjunto de datos con los valores de hiperparámetros óptimos.

El método Hold-out es una técnica de ML que puede ser usada para evitar el overfitting o underfitting en los modelos desarrollados (Kumar A. , 2022).

Figura 26

Hold out para selección de modelo de predicción



En (Levman, et al., 2021) se demostró que el método Hold-out que involucra la división aleatoria del conjunto de datos para entrenamiento y validación son adaptables en modelos de regresión.

Categorización de algoritmos de aprendizaje

- Aprendizaje supervisado

Un algoritmo de aprendizaje supervisado ajusta las fuerzas o pesos de las conexiones entre neuronas de acuerdo con la diferencia entre las salidas de red deseadas y reales correspondientes a una entrada dada. Por lo tanto, el aprendizaje supervisado requiere que un maestro o supervisor proporcione las señales de salida deseadas o de destino.

- Aprendizaje no supervisado

Los algoritmos de aprendizaje no supervisados no requieren que se conozcan los resultados deseados. Durante el entrenamiento, solo los patrones de entrada se presentan a la red neuronal, que adapta automáticamente los pesos de sus conexiones para agrupar los patrones de entrada en grupos con características similares.

Procesamiento de datos

Un paso importante en la tarea de análisis de datos, es graficarlos. Los gráficos permiten visualizar muchas características, incluidos patrones, observaciones inusuales, cambios a lo largo del tiempo y relaciones entre variables. Las características que se ven en los gráficos de los datos deben incorporarse, tanto como sea posible, en los métodos de pronóstico que se utilizarán. Así como el tipo de datos determina qué método de pronóstico usar, también determina qué gráficos son apropiados

Patrones de series de tiempo

Al elegir un método de pronóstico, se requiere identificar los patrones de tiempo en los datos y luego elegir un método que pueda capturar los patrones correctamente.

- Tendencia

Existe cuando hay un aumento o disminución a largo plazo en los datos. No tiene que ser lineal.

- Estacional

Ocurre cuando una serie de tiempo se ve afectada por factores estacionales como la época del año o el día de la semana. La estacionalidad es siempre de un período fijo y conocido.

- Cíclico

Ocurre cuando los datos exhiben subidas y bajadas que no tienen una frecuencia fija. Si las fluctuaciones no son de una frecuencia fija entonces son cíclicas; si la frecuencia no cambia y está asociada con algún aspecto del calendario, entonces el patrón es estacional. En general, la duración media de los ciclos es mayor que la duración de un patrón estacional, y las magnitudes de los ciclos tienden a ser más variables que las magnitudes de los patrones estacionales. Muchas series de tiempo incluyen tendencia, ciclos y estacionalidad. (Hyndman & Athanasopoulos, 2022)

Los picos y componentes no estacionarios de los datos de entrada de los modelos de producción de energía fotovoltaica están entrenados de manera inadecuada y esto conducirá a un alto error de predicción. Estos problemas siempre existen, ya que la mayoría de los modelos utilizan datos meteorológicos y datos históricos de producción de energía fotovoltaica como entradas, que son variables e impredecibles debido a las condiciones climáticas. Por lo tanto, el procesamiento previo de los datos de entrada puede disminuir el problema de entrenamiento inadecuado y el costo computacional, mejorando considerablemente la precisión del modelo (Konstantinou, Peratikou, & Charalambides, 2021).

Escasez de datos

En conjunto de datos recopilados de la salida de energía fotovoltaica incluyen valores nocturnos, donde hay una presencia de muchos ceros en la salida de energía fotovoltaica. El problema de escasez de datos ocurre porque demasiados valores cero conducen a un modelo mal entrenado que afecta el rendimiento del modelo. Por lo tanto, la escasez de datos en los datos de entrada es un factor importante que puede afectar la precisión de la predicción. Para evitar este problema, la mayoría de los valores nocturnos se eliminan (Konstantinou, Peratikou, & Charalambides, 2021).

Estandarización de datos

Para un mejor ajuste y protección del entrenamiento de divergencias, la secuencia de datos de entrenamiento está estandarizada para tener una media cero y una varianza unitaria (Kumar, Mathur, Bhanot, & Bansal, 2020).

$$PV_{STD}(i) = \frac{PV_{Train}(i) - \mu}{\sigma_{Train}} \quad (19)$$

Donde PV_{STD} es el valor de potencia fotovoltaica estandarizada, PV_{Train} es cada valor de potencia fotovoltaica del conjunto de datos, μ es la media del conjunto de datos de potencia fotovoltaica y σ_{Train} es la desviación estándar del conjunto de datos de potencia fotovoltaica.

Normalización de datos

Los datos de entrada consisten en la salida de potencia fotovoltaica que varía entre 0 y la potencia de salida nominal. Por lo tanto, al manejar algunos datos de gran valor con el modelo basado en RNN, se puede producir una explosión de gradiente y afectar negativamente el rendimiento del modelo. Además, se reducirá la eficacia de aprendizaje. Para solucionar este problema, los datos de entrada se normalizan a través de la normalización mínimo – máximo dentro del intervalo [0,1] y luego se usan para construir los modelos de aprendizaje profundo (Dairi, Harrou, Sun, & Khadraoui, 2020).

$$PV_{Norm}(i) = \frac{PV_{Train}(i) - PV_{min}}{PV_{max} - PV_{min}} \quad (20)$$

Donde PV_{Norm} es el valor de potencia fotovoltaica normalizada, PV_{min} es el menor valor de potencia fotovoltaica del conjunto de datos y PV_{max} es el mayor valor de potencia fotovoltaica del conjunto de datos.

Técnicas de evaluación de modelos

Los métodos de aprendizaje permiten construir modelos a partir de un conjunto de datos y es importante conocer con exactitud el nivel de precisión de estos modelos aprendidos. Como se mencionó en el capítulo de Alcance del presente documento, existen métricas de desempeño de los modelos de predicción, a continuación, se los describe y se muestra su expresión matemática.

RMSE

Se puede utilizar si hay valores atípicos que deben detectarse. Es más sensible a grandes desviaciones entre los pronósticos y datos reales. RMSE indica el nivel de dispersión que produce el modelo. Un RMSE más bajo indica que el modelo desarrollado tiene una buena precisión de predicción, ver Ecuación (21).

MAE

Se puede utilizar si los valores atípicos representan partes dañadas de los datos. De hecho, MAE no penaliza demasiado los valores atípicos de entrenamiento proporcionando así una medida de rendimiento genérica y acotada para el modelo. Por otro lado, si el conjunto de prueba también tiene muchos valores atípicos, el rendimiento del modelo será mediocre. MAE es una media adecuada cuando se asume que los errores de pronóstico son proporcionales a los costos de energía, ver Ecuación (22).

MAPE

Se define como una cantidad que se utiliza para medir que tan cerca están los valores predichos de los valores medidos. Tiene una interpretación intuitiva en términos de error relativo: por su definición, se recomienda su uso en tareas donde es más importante ser sensible a variaciones relativas que a variaciones absolutas. Sin embargo, también tiene una serie de inconvenientes, siendo los más críticos la restricción de su uso a datos estrictamente positivos por definición y su sesgo hacia pronósticos bajos, lo que lo hace inadecuado para modelos predictivos donde se esperan grandes errores, ver Ecuación (23) (Chicco, Warrens, & Jurman, 2021).

Coeficiente de correlación

El valor del coeficiente de correlación lineal se utiliza para encontrar la relación entre los valores medidos y predichos. Si tiene el valor de 1 significa que existe una relación lineal exacta entre los valores medidos y predichos, ver Ecuación (24) (Neelamegam & Arasu Amirtham, 2016).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (21)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (22)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (23)$$

$$Cor. coef. = \frac{1}{n-1} \sum_{i=1}^n \left(\frac{y_i - \mu_{y_i}}{\sigma_{y_i}} \right) \left(\frac{\hat{y}_i - \mu_{\hat{y}_i}}{\sigma_{\hat{y}_i}} \right) \quad (24)$$

Donde y_i es cada valor real de potencia, μ_{y_i} es la media del conjunto de datos de potencia real, σ_{y_i} es la desviación estándar del conjunto de datos de potencia real, \hat{y}_i es cada valor de real predicha, $\mu_{\hat{y}_i}$ es la media del conjunto de datos de potencia predicha, $\sigma_{\hat{y}_i}$ es la desviación estándar del conjunto de datos de potencia predicha y n es el número de muestras.

Capítulo III. Metodología

La metodología seguida en el presente trabajo para llevar a cabo la predicción de energía fotovoltaica se muestra en el diagrama de flujo de la Figura 27. A continuación, se desarrollan las diferentes etapas inmersas en el proceso.

Selección de zonas aisladas

Como se mencionó en el apartado de Energías Renovables en Ecuador, las Islas Galápagos constituyen una locación factible para la implementación de sistemas aislados basados en ERNC. Por lo tanto, a continuación, se describen las zonas seleccionadas. Zona 1: Isla Santa Cruz (0°41'42"S 90°19'44.399"W) y Zona 2: Isla San Cristóbal (0°54'0"S 89°30'21.6"W). La Figura 28 muestra su ubicación geográfica. Estas islas corresponden a las más pobladas de la región y son tomadas como caso de estudio.

Figura 27

Diagrama de flujo para predicción de energía fotovoltaica

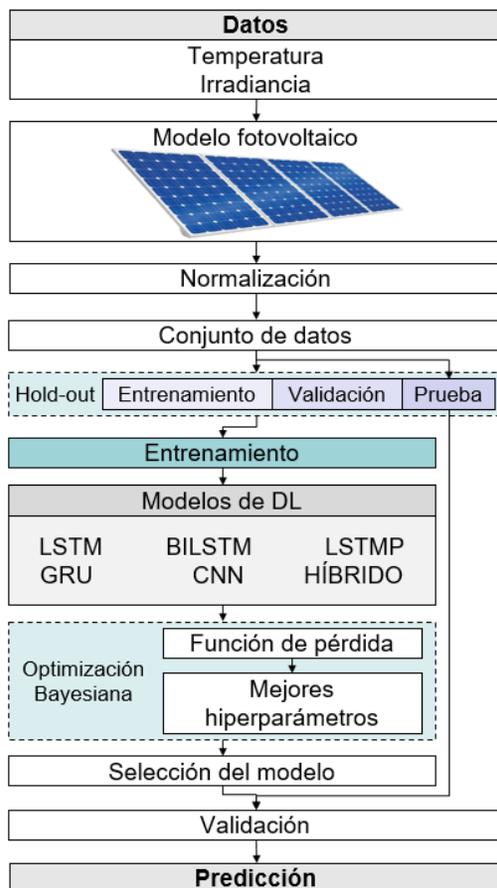


Figura 28

Zonas de estudio de caso

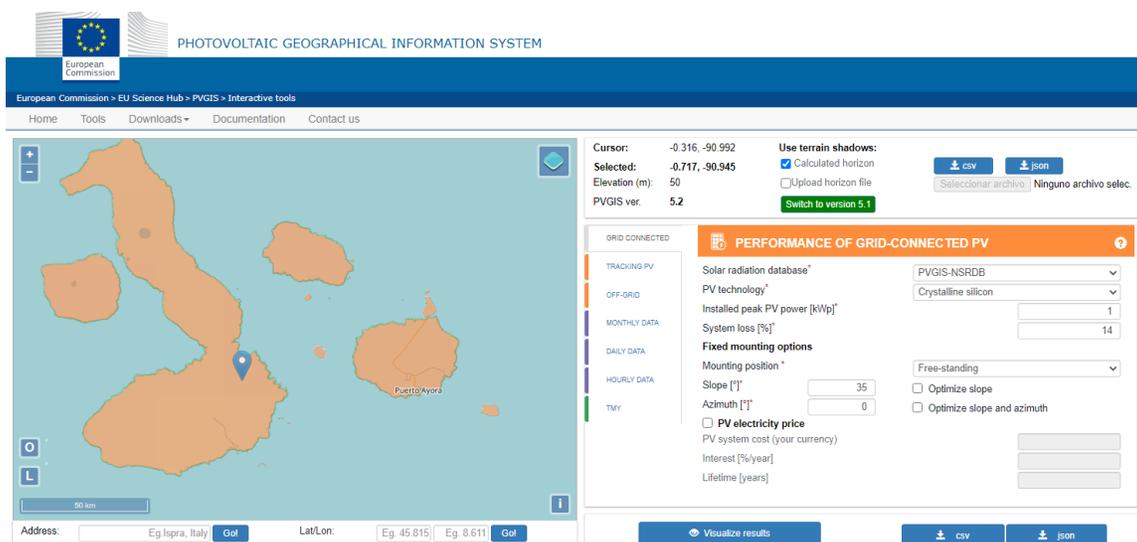


Obtención de datos

Los datos para entrenar los algoritmos son obtenidos desde el sitio web Photovoltaic Geographical Information System (PVGIS). La Figura 29 muestra la página para la obtención de datos. La colección de datos desde el año 2018 al 2020 corresponde a los valores de temperatura e irradiancia en cada hora. Según el modelo del panel fotovoltaico, estos datos sirven como parámetros para la obtención de energía eléctrica generada por un módulo fotovoltaico.

Figura 29

Portal PVGIS en Islas Galápagos



Nota. Adaptado de *PVGIS Interactive tool*, por EU Science Hub, 2022

(https://re.jrc.ec.europa.eu/pvg_tools/en/)

La Figura 30 muestra la potencia fotovoltaica obtenida al aplicar las ecuaciones (2) y (3) al conjunto de datos de la zona 1 bajo estudio. Se puede apreciar que existe una variación estacionaria durante los años 2018 al 2020. Debido a la proximidad geográfica entre ambas islas, existen similares condiciones climáticas. Consecuentemente, la potencia fotovoltaica alcanza valores similares. Tal como lo muestra la Figura 31, donde existe una correlación

positiva entre los datos de potencia fotovoltaica obtenida en la locación 1 y locación 2. Por lo tanto, los datos para la obtención de los hiperparámetros optimizados corresponden a la locación 1 y estos valores pueden ser usados para validar los modelos para ambas locaciones.

Figura 30

Variación de potencia fotovoltaica para la Isla Santa Cruz

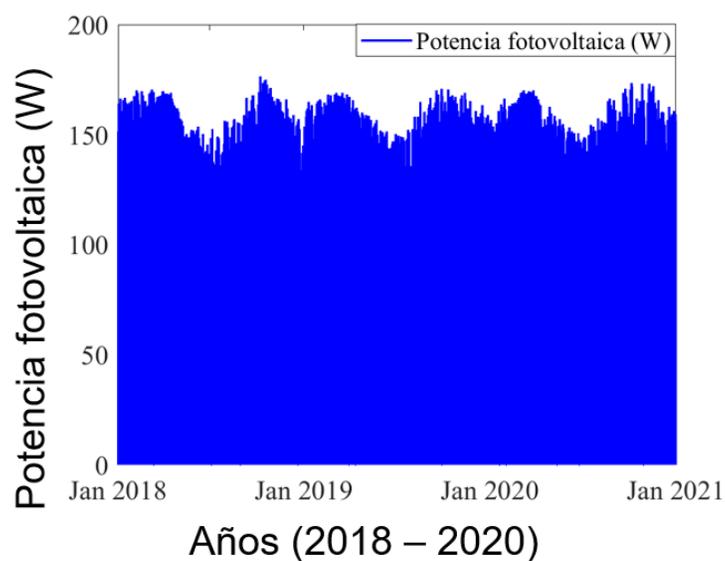
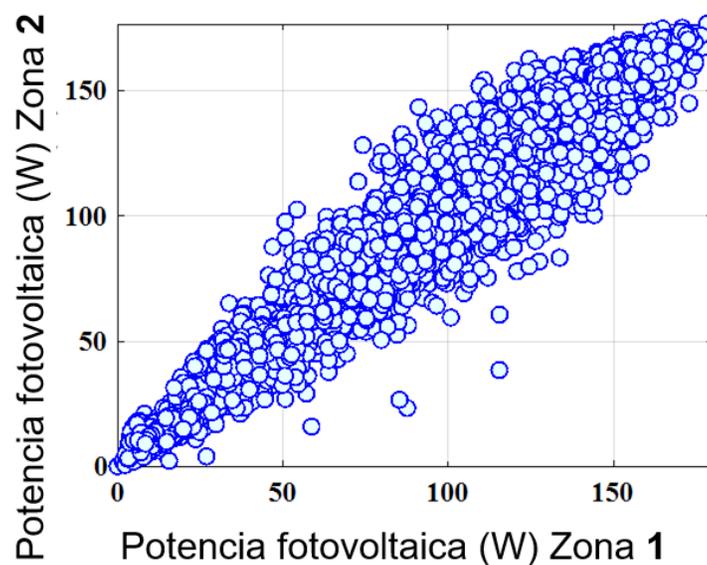


Figura 31

Correlación de potencia fotovoltaica entre Isla Santa Cruz e Isla San Cristóbal



Procesamiento de datos

El conjunto de datos es dividido en 80% para entrenamiento (PV_{Train}) y 20% para prueba (PV_{Test}). Los datos de entrada consisten en la potencia fotovoltaica del rango de 0 a la potencia nominal dada por el panel. A partir de esto, al manipular algunos valores altos con los métodos basados en RNN, la explosión del gradiente puede ocurrir y afectar negativamente el desempeño del modelo. Adicionalmente, la eficiencia de aprendizaje es reducida. Para resolver este problema, los datos de entrada son normalizados dentro del intervalo $[0,1]$ y son usados para construir los modelos de DL (Dairi, Harrou, Sun, & Khadraoui, 2020). El presente trabajo realizó una comparación de desempeño entre el modelo GRU desarrollado en el trabajo anterior (Guanoluisa-Pineda, et al., 2022) al estandarizar y normalizar los datos. Los resultados obtenidos se muestran en la Tabla 6. Como se puede observar, existe una notable diferencia y disminución del error al entrenar los modelos con datos normalizados frente a los estandarizados. Por lo tanto, se escoge la normalización como método de procesamiento para el desarrollo de los modelos del presente trabajo.

Tabla 6

Comparación desempeño datos normalizados y estandarizados

GRU	Normalización	Estandarización
RMSE	0.0197	0.0440
MAE	11.1676	11.9603
MAPE	106210	92668
Cor. Coef.	0.9526	0.9506

Entrenamiento de modelos

Los modelos LSTM, LSTMP, BiLSTM, GRU, CNN e Híbrido son entrenados de forma supervisada. El optimizador Adam es utilizado para todos los métodos para minimizar la función

de pérdida en entrenamiento. El algoritmo de Optimización Bayesiana es utilizado para la obtención de hiperparámetros. Los hiperparámetros buscados son el número de épocas, número de capas ocultas, tasa de aprendizaje el tamaño y número de filtros para los modelos que incluyen CNN en su arquitectura. Con el método Hold-out, el conjunto de datos PV_{Train} es dividido en 80% para entrenamiento PV_{Train_t} y 20% para validación PV_{Train_v} . La selección de las muestras es realizada de forma aleatoria como se muestra en la Figura 32.

Figura 32

Hold-out aplicado al conjunto de datos de locación 1

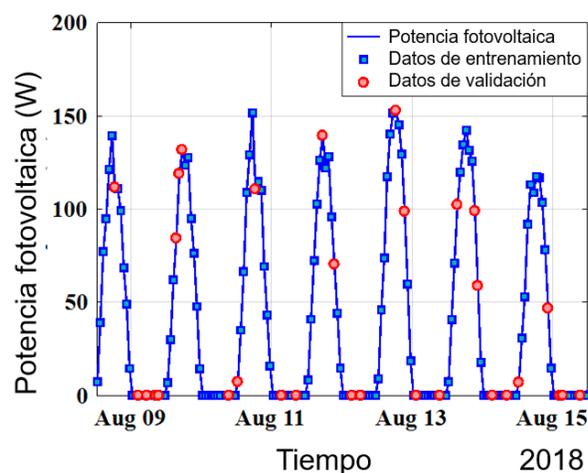
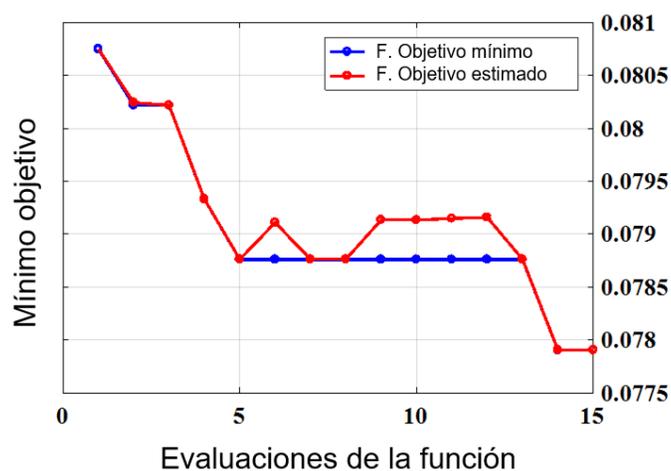


Figura 33

Optimización Bayesiana para hiperparámetros del modelo Híbrido



La Figura 33 muestra la evolución de la optimización Bayesiana de los hiperparámetros para el modelo híbrido, donde los valores con la menor pérdida son seleccionados.

La Tabla 7 muestra los valores de los hiperparámetros óptimos para los seis modelos del presente trabajo. Para el método LSTMP, Var. 1 y Var. 2 corresponden al tamaño del proyector de entrada y salida respectivamente. Para los modelos CNN e Híbrido Var. 1 y Var. 2 corresponden al tamaño y número de filtros respectivamente. Cabe notar que, para el método híbrido, menores valores son requeridos para la extracción de características respecto al método CNN, el cual no incluye una capa de RNN.

Tabla 7

Hiperparámetros optimizados para predicción

Método	Épocas	Capas ocultas	Tasa de aprendizaje	Var. 1	Var. 2
LSTM	225	159	0.0084568		
LSTMP	159	265	0.0099320	9	25
BiLSTM	177	254	0.0099758		
GRU	156	247	0.0099982		
CNN	197		0.0001134	31	27
Hybrid	150	96	0.0012401	9	17

Validación

Los seis modelos de DL son entrenados con los hiperparámetros mostrados en la Tabla 7, con los datos de ambas locaciones bajo estudio. Para validar los resultados se utilizan las métricas mostradas en el apartado de evaluación de técnicas, con las Ecuaciones (21) – (24).

El link de acceso al código se muestra a continuación:

<https://github.com/RichardGuanoluisa/PVForecast.git>

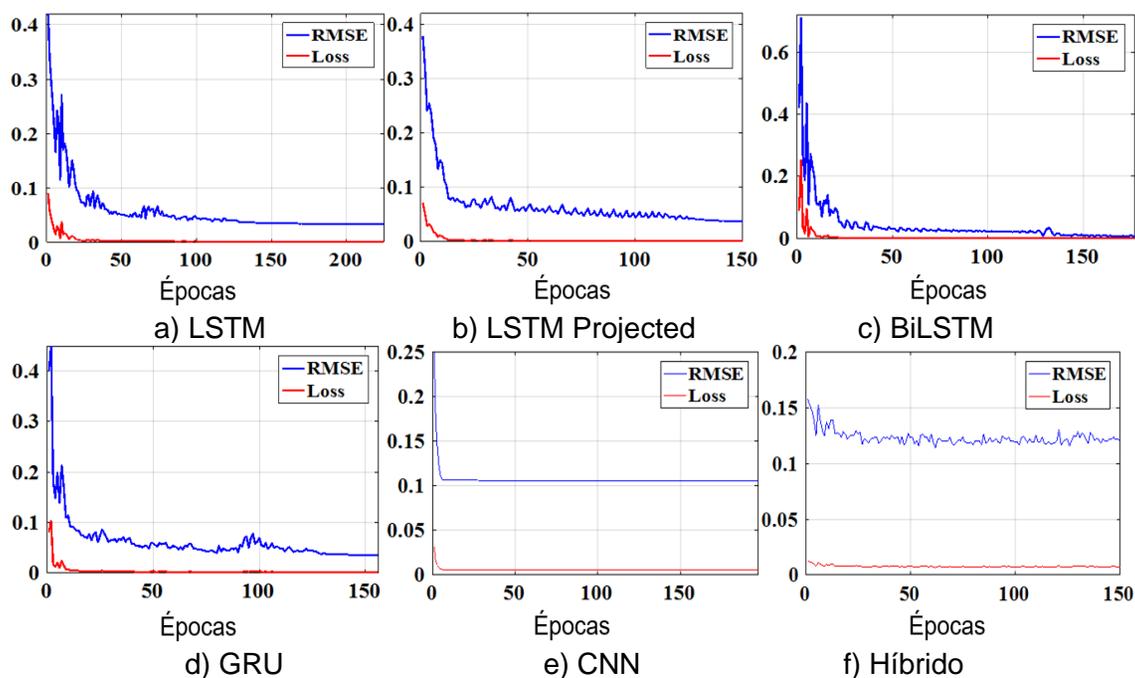
Capítulo IV. Resultados

Las simulaciones de los algoritmos de predicción fueron desarrolladas mediante Matlab®, utilizando un computador con Procesador Intel® Core™ i7-3770 y 8Gb de RAM. A continuación, se describen los resultados obtenidos.

La Figura 34 muestra la curva de entrenamiento para el conjunto de datos de la locación 1. El valor del error disminuye conforme el número óptimo de iteraciones. Adicionalmente, el valor de la función de pérdida no muestra fluctuaciones después del número óptimo de épocas, lo cual implica que los parámetros ya han sido aprendidos. Se puede notar que para el método CNN la curva de entrenamiento es más suavizada que los otros métodos debido a los filtros aplicados a los datos de entrada. En contraste con los métodos basados en RNN que lidian con los cambios temporales de potencia fotovoltaica.

Figura 34

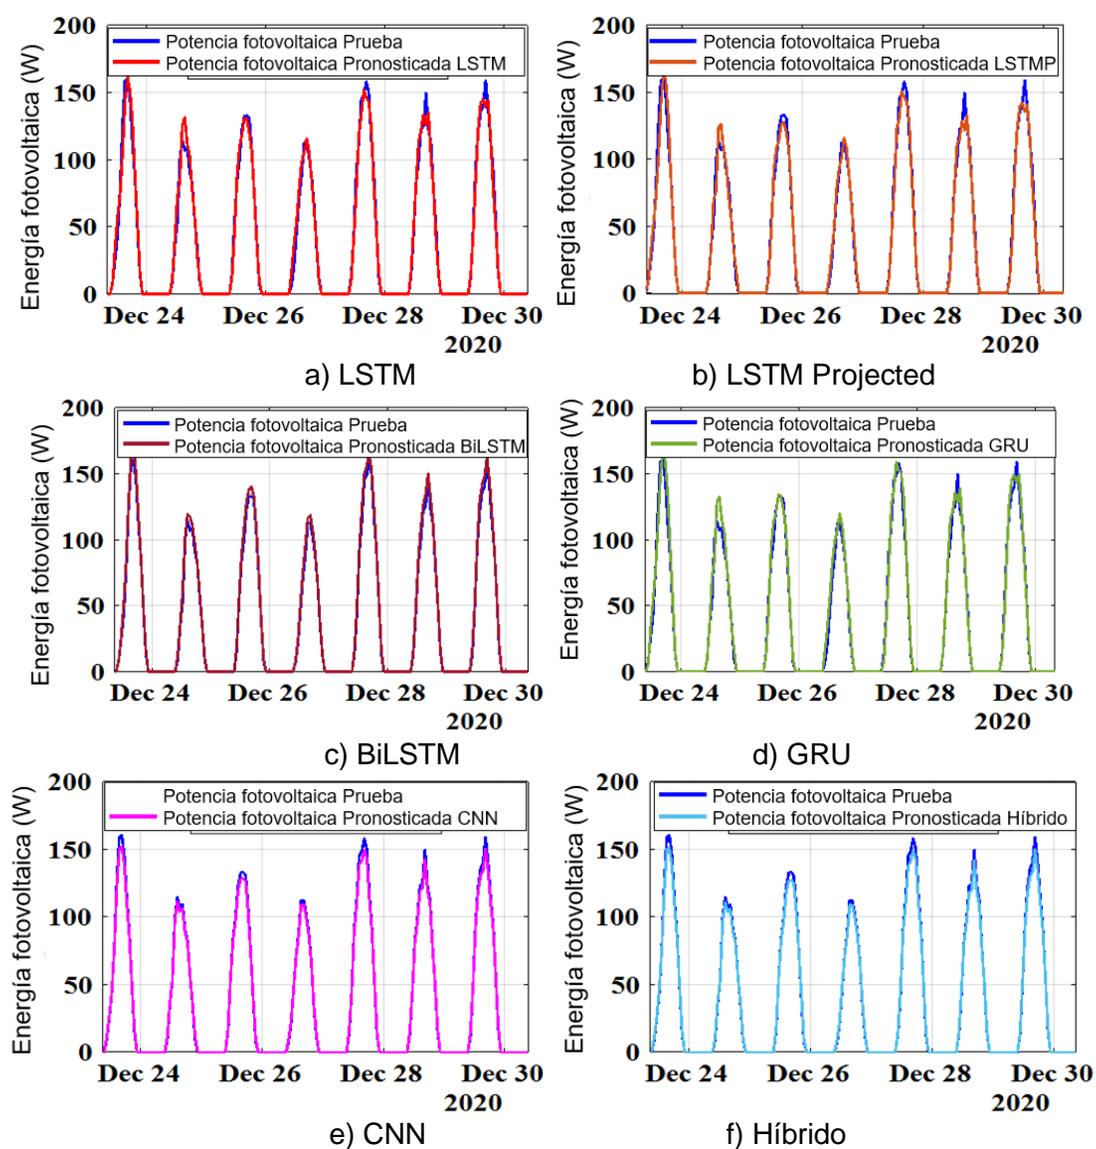
RMSE de entrenamiento de los modelos de DL



Adicionalmente, la Figura 35 muestra la potencia fotovoltaica verdadera y pronosticada para una semana en el conjunto de datos de la locación 1 con los seis modelos de DL. Como se puede observar, todos los métodos presentan una excelente aproximación de los valores pronosticados a los valores reales. Sin embargo, pequeñas diferencias pueden ser observadas.

Figura 35

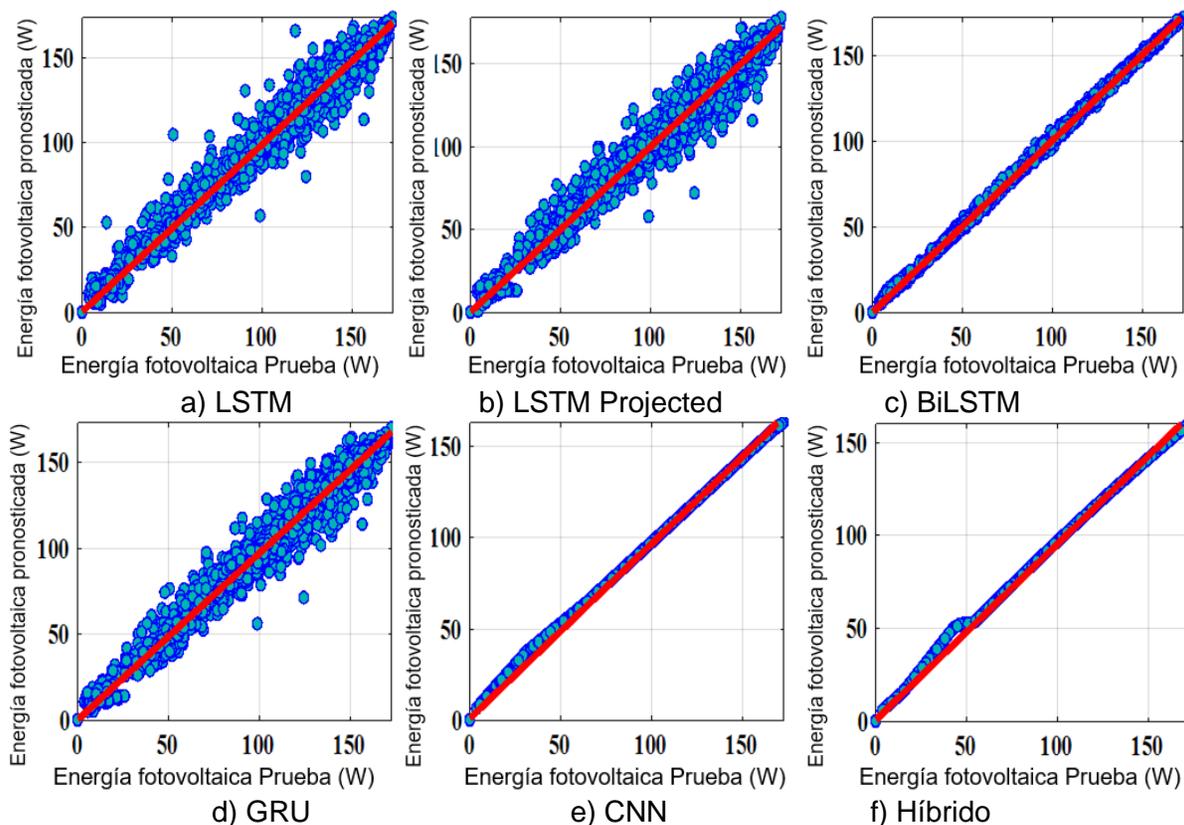
Energía fotovoltaica real y pronosticada para Locación 1



Además, la Figura 36 el gráfico de correlación entre la potencia real y pronosticada de todos los métodos para el período completo de prueba de la locación 1. Los resultados obtenidos implican una dependencia lineal entre las variables. Resultados similares son obtenidos con los métodos LSTM, LSTMP y GRU, pero los resultados obtenidos con BiLSTM, CNN e Híbrido muestran mejor desempeño al acercarse más a los valores reales. Con lo anteriormente descrito, todos los métodos con sus hiperparámetros óptimos son eficientes para la predicción.

Figura 36

Gráfico de correlación para los métodos de DL en locación 1



Los indicadores de desempeño son utilizados para determinar las ventajas cuantitativas de un método sobre otro. Como se muestra en la Tabla 8, todos los métodos desarrollados realizan una eficiente predicción de energía fotovoltaica. En este sentido, el RMSE obtenido es

pequeño, lo que indica una alta precisión en la predicción. Además, los valores de MAE y MAPE indican baja diferencia entre los valores reales y pronosticados. Por otro lado, el valor del coeficiente de correlación obtenido es cercano a 1, lo que significa dependencia lineal entre los valores reales con los pronosticados.

Tabla 8

Métricas de desempeño en locación 1

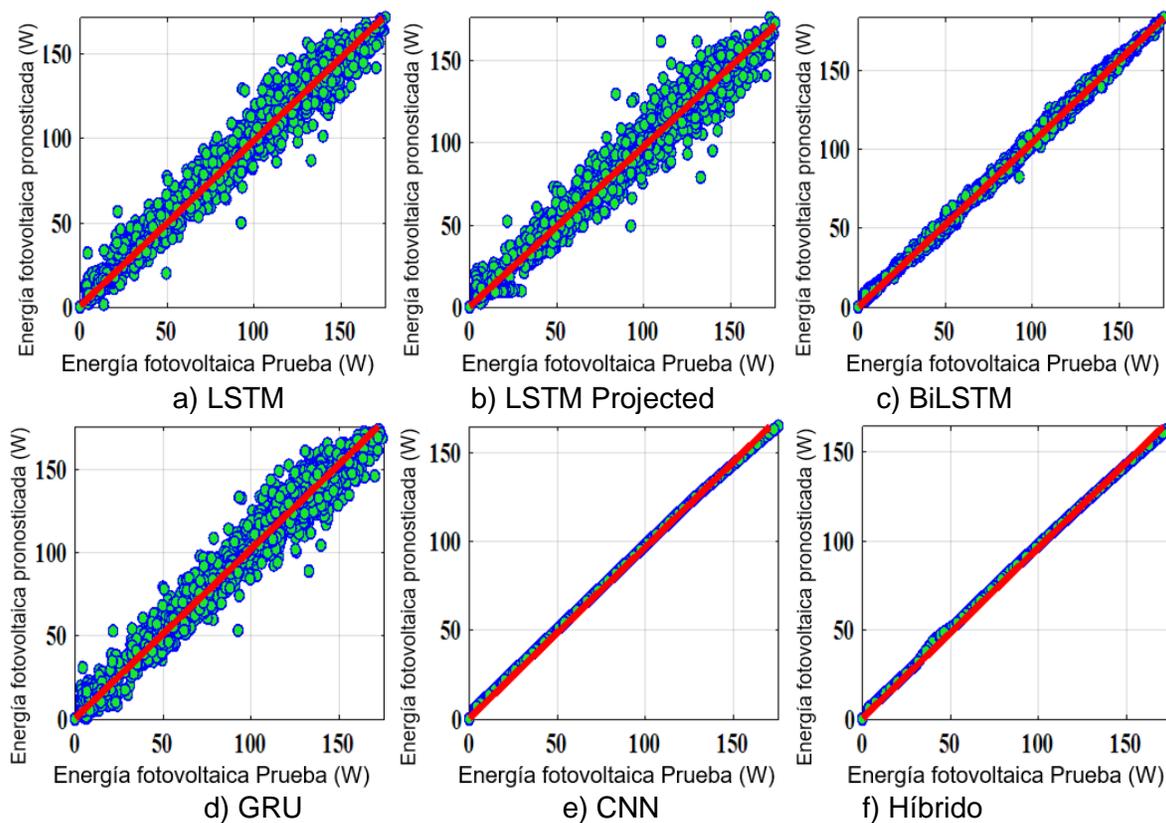
Método	RMSE	MAE	MAPE	Cor. Coef.
LSTM	0.0030	2.5577	0.5551	0.9962
LSTMP	0.0027	2.5682	0.5542	0.9960
BiLSTM	0.0032	2.6216	0.5206	0.9998
GRU	0.0097	2.6405	0.5601	0.9961
CNN	0.0124	2.0914	0.5456	0.9994
Hybrid	0.0196	2.1354	0.5269	0.9994

De forma similar, la Figura 37 muestra el gráfico de correlación entre la potencia fotovoltaica real y la pronosticada para la locación 2. De la misma forma. Que los resultados obtenidos con los datos de la locación 1, los modelos presentaron gran precisión en la predicción. Nuevamente, los modelos BiLSTM, CNN e Híbrido demostraron mejor desempeño.

Adicionalmente, las métricas de desempeño para la locación 2 se muestran en la Tabla 9. Se puede apreciar que los valores de error obtenidos son bajos y similares a los obtenidos en la locación 1. Además, la optimización Bayesiana demostró ser capaz de obtener hiperparámetros optimizados para los 6 modelos de DL, los cuales pueden ser usados en la tarea de predicción en áreas aisladas como las de los casos de estudio. Debido al bajo error obtenido en la predicción para ambos conjuntos de datos, la metodología aplicada en este trabajo demostró ser eficiente en la obtención de modelos de DL precisos.

Figura 37

Gráfico de correlación para los métodos de DL en locación 2

**Tabla 9**

Métricas de desempeño en locación 2

Método	RMSE	MAE	MAPE	Cor. Coef.
LSTM	0.0012	2.9339	0.5841	0.9951
LSTMP	0.0081	3.1643	0.5847	0.9943
BiLSTM	0.0027	2.0542	0.5470	0.9996
GRU	0.0192	3.1992	0.5852	0.9948
CNN	0.0145	1.5066	0.5341	0.9998
Híbrido	0.0163	1.7144	0.5336	0.9997

Adicionalmente, la Figura 38 compara los valores de RMSE obtenidos para todos los modelos en ambos conjuntos de datos, como se puede observar el modelo LSTM obtiene un valor más bajo que el modelo BiLSTM. Esto indica que las características de la serie temporal no necesitan las capas de backward y feedforward para aprender. Sin embargo, estos modelos capturaron mejor los cambios temporales en contraste con los demás métodos GRU, CNN e Híbrido, los cuales obtuvieron valores de RMSE más altos en la predicción.

De igual forma, la Tabla 10 compara los tiempos de entrenamiento para todos los modelos con el fin de evaluar el desempeño computacional, donde la Figura 39 muestra una representación visual de estos valores. Como se puede apreciar, los modelos LSTM, GRU, CNN e Híbrido obtienen tiempos de entrenamiento más bajos. Específicamente, el modelo BiLSTM obtuvo el tiempo de entrenamiento más alto debido a que este método utiliza dos capas de entrenamiento, la BP y feedforward (correspondientes a dos celdas LSTM). Sin embargo, debido a que obtiene un alto valor de RMSE, la característica de doble capa es innecesaria para el tipo de datos utilizados en este trabajo.

Figura 38

Comparación de RMSE para los métodos desarrollados

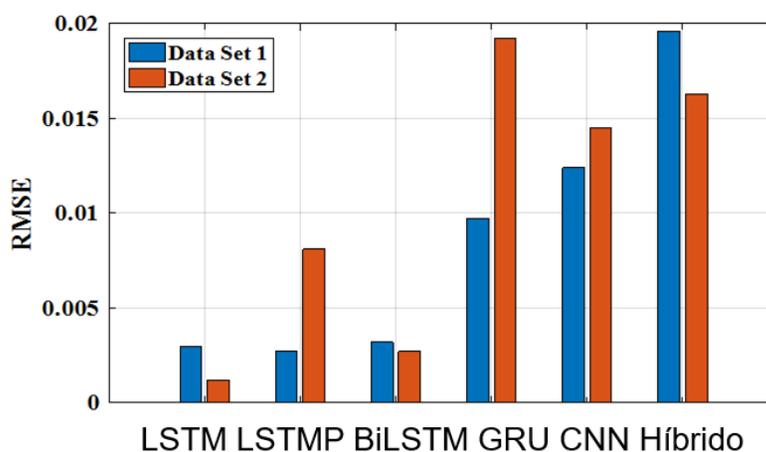
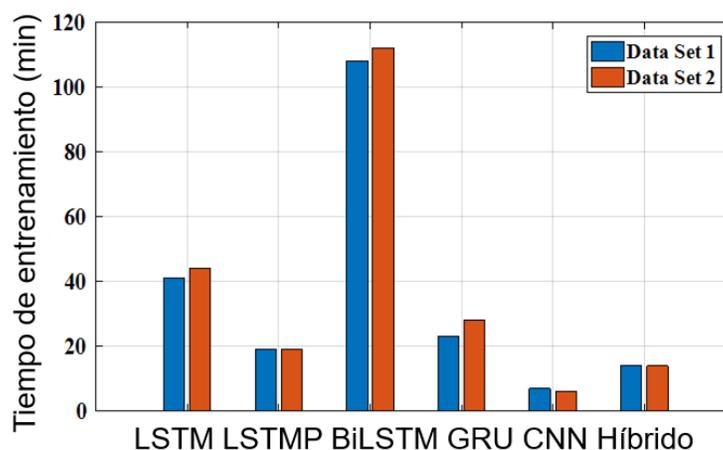


Tabla 10*Desempeño computacional*

Método	Tiempo de entrenamiento (min)	
	Locación 1	Locación 2
LSTM	41	44
LSTMP	19	19
BiLSTM	108	112
GRU	23	28
CNN	7	6
Híbrido	14	14

Debido a que el modelo LSTM logró un valor bajo de RMSE en la predicción y tiempo de entrenamiento, el modelo desarrollado con los hiperparámetros optimizados puede aprender adecuadamente los cambios temporales de la potencia fotovoltaica en ambas locaciones de estudio a diferencia de los otros modelos.

Figura 39*Tiempo de entrenamiento para los modelos de DL*

Finalmente, para verificar la efectividad de la OB en la obtención de los hiperparámetros en contraste con los modelos desarrollados en el trabajo anterior (Guanoluisa-Pineda, et al., 2022).

La Tabla 11 compara los resultados obtenidos con los métodos LSTM y GRU con y sin hiperparámetros optimizados. Como se puede ver, la OB redujo el número de épocas para ambos métodos, lo cual implica reducción en el costo computacional.

También, para el método LSTM, el número de capas ocultas (NCO) es disminuido, lo que reduce la complejidad de la red. Sin embargo, para el método GRU, el NCO incrementó, lo que implica que el modelo requiere de más capas ocultas para aprender los cambios temporales de la energía fotovoltaica. Cabe notar que el desempeño de los métodos con hiperparámetros optimizados tienen menor valor de error y coeficiente de correlación más altos.

Por lo tanto, la OB permitió obtener mejor desempeño de los métodos de DL y modelos más precisos con valores reducidos de hiperparámetros y menor costo computacional.

Tabla 11

Comparación de desempeño

Método	Hiperparámetros		Evaluación de desempeño	
	Épocas	NCO	RMSE	Corr. Coef.
LSTM	250	200	0.0517	0.9514
GRU	250	200	0.0023	0.9528
LSTM optimizado	225	159	0.0030	0.9962
GRU optimizado	156	237	0.0097	0.9961

Conclusiones

Se presentó el abundante recurso solar en Ecuador y la necesidad de utilizar energías renovables no convencionales como fuente de energía primaria en áreas aisladas que no están conectadas al SNI.

Las Islas Galápagos poseen un gran potencial para la explotación del recurso solar, debido a que el GHI de 4.8 – 6.3 kWh/m² de la región supera la base de 3.8 kWh/m² a partir del cual un sistema fotovoltaico es viable.

Se desarrollaron los modelos de predicción de potencia fotovoltaica LSTM, LSTM, BiLSTM, CNN e Híbrido para dos áreas aisladas en las Islas Galápagos de Ecuador.

La normalización de datos permitió obtener mayor precisión en el entrenamiento de los modelos, ya que, al comparar los resultados de predicción obtenidos con el modelo GRU, se redujo el RMSE de predicción del 0.0440 con datos estandarizados a 0.0197 con datos normalizados.

Los modelos desarrollados han mostrado excelente desempeño en la predicción de energía fotovoltaica. La correlación del 99% alcanzada entre los valores reales y pronosticados de ambas locaciones por todos modelos indica la eficiencia de aprendizaje, por lo cual, los modelos desarrollados son eficientes en el pronóstico de energía fotovoltaica basada en el modelo de panel solar. Sin embargo, LSTM ha presentado un mejor desempeño en el aprendizaje de los cambios temporales, ya que su RMSE de 0.0030 y 0.0012 para ambas locaciones es el menor comparado con el RMSE obtenido para los demás métodos. Por lo tanto, se puede utilizar como referencia para implementar sistemas solares fotovoltaicos aislados en las Islas Galápagos.

La optimización bayesiana permitió obtener los hiperparámetros óptimos necesarios para el entrenamiento de los modelos. Esto ha reducido el costo computacional y el error en el

pronóstico, para el modelo LSTM se disminuyó el RMSE de predicción del 0.0517 con hiperparámetros sin optimizar al 0.0030 con hiperparámetros optimizados.

Según la precisión de predicción obtenida y la disminución del costo computacional, la metodología propuesta demostró ser eficiente para la tarea de entrenamiento de los métodos de DL. Además, el procedimiento se puede implementar para pronosticar la energía fotovoltaica en muchas áreas con este prerrequisito.

Recomendaciones

Considerar áreas válidas en las Islas Galápagos para la obtención de datos, debido a que la página PVGIS puede carecer de datos necesarios para la obtención de energía fotovoltaica.

Graficar los datos de entrenamiento disponibles para evidenciar las características y comportamiento temporal, con el fin de evaluar posibles técnicas de procesamiento.

Considerar el tiempo de muestreo de los datos para evitar la pérdida de información, es decir, si se aumenta el tiempo entre cada dato, los cambios de energía fotovoltaica se vuelven demasiado bruscos, por lo que la tendencia de los datos cambiaría y no reflejaría su comportamiento real.

Evaluar diferentes técnicas de procesamiento de datos para obtener mejor desempeño de las técnicas de DL.

Implementar un método de optimización en la obtención de hiperparámetros de entrenamiento de los modelos para disminuir el tiempo de entrenamiento y coste computacional.

Experimentar con varios conjuntos de datos para validar la efectividad de la optimización Bayesiana en la búsqueda de los hiperparámetros de entrenamiento de los modelos de DL.

Establecer un rango adecuado de búsqueda de los mejores hiperparámetros para la optimización Bayesiana, debido a que los resultados pueden no ser útiles para los modelos de predicción.

Trabajos futuros

Como trabajos futuros se proponen analizar la similitud de energía fotovoltaica de las demás islas para el desarrollo de modelos de predicción fotovoltaica para toda la región. Además, utilizar las diferentes técnicas de DL en otras aplicaciones de gestión de energía, como el análisis de salud del estado de carga de baterías.

Reconocimientos

Este trabajo es parte del proyecto 2020-EXT-007 “MIRA-ESTE: Specific, innovative microgrids solutions (accounting for environmental, social, technological and economic aspects) for isolated rural areas of Ecuador” desarrollado en conjunto con la Universidad KU Leuven (Bélgica) con el financiamiento del Consejo Interuniversitario Flamenco (VLIR-UOS) y la Agencia de Cooperación Belga para el Desarrollo (DGD) con el proyecto EC2020SIN322A101.

El trabajo anterior (Guanoluisa-Pineda, et al., 2022) corresponde al artículo titulado Short-Term forecasting of photovoltaic power in an isolated area of Ecuador using deep learning techniques publicado en The 11th International Conference on Renewable Energy Research and Application (ICRERA), desarrollado del 18 al 21 de septiembre de 2022, en la ciudad de Estambul, Turquía. El artículo recibió el premio como *Outstanding Paper Award* al ser considerado uno de los mejores artículos presentados en el congreso.

Bibliografía

- Agencia de Regulación y Control de Energía y Recursos Naturales no Renovables. (2021). *ATLAS del sector eléctrico ecuatoriano*. <https://www.controlrecursosyenergia.gob.ec/wp-content/uploads/downloads/2022/04/Atlas2021.pdf>
- Agencia de Regulación y Control de Energía y Recursos Naturales No Renovables. (2021). *Estadística anual y multianual del sector eléctrico ecuatoriano*.
- Agga, A., Abbou, A., Labbadi, M., & El Houm, Y. (2021). Short-term self consumption PV plant power production forecasts based on hybrid CNN-LSTM, ConvLSTM models. *Renewable Energy*, 177, 101-112. <https://doi.org/10.1016/j.renene.2021.05.095>
- Ahmed, A., & Khalid, M. (2019). A review on the selected applications of forecasting models in renewable power systems. *Renewable and Sustainable Energy Reviews*, 100, 9-21. <https://doi.org/10.1016/j.rser.2018.09.046>
- Arcos-Aviles, D., Guinjoan, F., Pascual, J., Marroyo, L., Gordillo, R., Sanchis, P., . . . Ibarra, A. (2018). Fuzzy-based energy management of a residential electro-thermal microgrid based on power forecasting. *44th Annual Conference of the IEEE Industrial Electronics Society*, 1824-1829. 10.1109/IECON.2018.8591575
- Arcos-Aviles, D., Pascual, J., Guinjoan, F., Marroyo, L., Sanchis, P., & Marietta, M. (2017). Low Complexity Energy Management Strategy for grid profile smoothing of a Residential Grid-Connected Microgrid using Generation and Demand Forecasting. *Applied Energy*, 205, 69-84. <https://doi.org/10.1016/j.apenergy.2017.07.123>.
- Arroyo M., F., & Miguel, L. (2020). The Role of Renewable Energies for the Sustainable Energy Governance and Environmental Policies for the Mitigation of Climate Change in Ecuador. *Energies*. <https://doi.org/10.3390/en13153883>
- Benghanem, M. (2012). Artificial intelligence techniques for prediction of solar radiation data: a review. *Int. J. Renewable Energy Technology*, 3(2), 189-220.

- Bird, R., & Hulstrom, R. (1981). A simplified clear sky model for direct and diffuse insolation on horizontal surfaces. *Solar Energy Research Institute*.
- Buturache, A.-N., & Stancu, S. (2021). Solar Energy Production Forecast Using Standard Recurrent Neural Networks, Long Short-Term Memory, and Gated Recurrent Unit. *Inzinerine Ekonomika-Engineering Economics*, 313–324.
<https://doi.org/10.5755/j01.ee.32.4.28459>
- Cavazza, M. (2021). *Towards Data Science*. Improve your model performance with Bayesian Optimization Hyperparameter Tuning. <https://medium.com/towards-data-science/improve-your-model-performance-with-bayesian-optimization-hyperparameter-tuning-4dbd7fe25b62>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*. 10.7717/peerj-cs.623
- Chitalia, G., Pipattanasomporn, M., Garg, V., & Rahman, S. (2020). Robust short-term electrical load forecasting framework for commercial buildings using deep recurrent neural networks. *Applied Energy*.
- Dairi, A., Harrou, F., Sun, Y., & Khadraoui, S. (2020). Short-Term Forecasting of Photovoltaic Solar Power Production Using Variational Auto-Encoder Driven Deep Learning Approach. *Appl. Sci.* <https://doi.org/10.3390/app10238400>
- ELECGALAPAGOS, S. (2021). *Rendición de cuentas*.
https://www.elecgalapagos.com.ec/public/lotaip/2022/FORMULARIOS/Presentacion_RC_2021.pdf
- Ellabban, O., Abu-Rub, H., & Blaabjerg, F. (2014). Renewable energy resources: Current status, future prospects and their enabling technology,. *Renewable and Sustainable Energy Reviews*, 39, 748-764. <https://doi.org/10.1016/j.rser.2014.07.113>

- Enríquez, E. (2019). Diseño y simulación de un sistema de previsión de generación fotovoltaica basado en la predicción numérica del clima. *Carrera de Ingeniería en Electrónica, Automatización y Control. Universidad de las Fuerzas Armadas ESPE*.
<http://repositorio.espe.edu.ec/handle/21000/15746>
- European Commission. (2022). *Photovoltaic Geographical Information System*.
https://re.jrc.ec.europa.eu/pvg_tools/es/#MR
- Fabara, C., Maldonado, D., Soria, M., & Tovar, A. (2019). Predicción de la Generación para un Sistema Fotovoltaico mediante la aplicación de técnicas de Minería de Datos. *energía(16)*, 64-72.
- Gordillo-Orquera, R., Lopez-Ramos, L. M., Muñoz-Romero, S., Iglesias-Casarrubios, P., Arcos-Avilés, D., G. Marques, A., & Rojo-Álvarez, R.-Á. (2018). Analyzing and Forecasting Electrical Load Consumption in Healthcare Buildings. *Energies*, 11.
<https://doi.org/10.3390/en11030493>
- Guanoluisa-Pineda, R., Ibarra, A., Arcos-Aviles, D., Martinez, W., Motoasca, E., & Guinjoan, F. (2022). Short-Term forecasting of photovoltaic power in an isolated area of Ecuador using deep learning techniques. *11th International Conference on Renewable Energy Research and Application (ICRERA)*, 408-413.
- Hamid Oudjana, S., Hellal, A., & Hadj Mahammed, I. (2014). Neural Network Based Photovoltaic Electrical Forecasting in South Algeria. *Applied Solar Energy*, 50(4), 273–277.
- Harrou, F., Kadri, F., & Sun, Y. (2020). Forecasting of Photovoltaic Solar Power Production Using LSTM Approach. *Advanced Statistical Modeling, Forecasting, and Fault Detection in Renewable Energy Systems*, 3-18.
- Hyndman, R., & Athanasopoulos, G. (2022). *Forecasting: principles and practice*. Melbourne, Australia: OTexts. <https://otexts.com/fpp3/>

- IBM Cloud Education. (2020). *Gradient Descent*. <https://www.ibm.com/cloud/learn/gradient-descent>
- Jarabo, F., Perez, C., Elortegui, N., Fernandez, J., & Macias, J. (1988). *El libro de las energías renovables*. Costa Rica.
- Jia, P., Zhang, H., Liu, X., & Gong, X. (2021). Short-Term Photovoltaic Power Forecasting Based on VMD and ISSA-GRU. *IEEE Access*, 9, 105939-105950.
10.1109/ACCESS.2021.3099169
- Jia, Y., Wu, Z., Xu, Y., Ke, D., & Su, K. (2017). Long Short-Term Memory Projection Recurrent Neural Network Architectures for Piano's Continuous Note Recognition. *Journal of Robotics*, 1-7. <https://doi.org/10.1155/2017/2061827>
- Kanchana, W., & Sirisukprasert, S. (2020). PV Power Forecasting with Holt-Winters Method. *2020 8th International Electrical Engineering Congress (iEECON)*, 1-4.
10.1109/iEECON48109.2020.229517
- Khan, A. T., Rehman, A., Li, S., Bakhsh, S., Mehmood, A., & Zaib, J. (2021). Optimally configured Gated Recurrent Unit using Hyperband for the long-term forecasting of photovoltaic plant. *Renewable Energy Focus*, 39, 49-58.
<https://doi.org/10.1016/j.ref.2021.07.002>
- Kingma, D., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *ICLR 2015*.
<https://arxiv.org/pdf/1412.6980.pdf>
- Konstantinou, M., Peratikou, S., & Charalambides, A. G. (2021). Solar Photovoltaic Forecasting of Power Output Using LSTM Networks. *Atmosphere*, 12. 10.3390/atmos12010124
- Koprinska, I., Wu, D., & Wang, Z. (2018). Convolutional Neural Networks for Energy Time Series Forecasting. *2018 International Joint Conference on Neural Networks (IJCNN)*, 1-8. 10.1109/IJCNN.2018.8489399

- Kumar Sahpp, A., & Kumar Sahoo, S. (2016). Energy Forecasting For Grid Connected MW Range Solar PV System. *7th India International Conference on Power Electronics (IICPE)*, 1-6. 10.1109/IICPE.2016.8079388.
- Kumar, A. (2022). *Data Analytics*. Hold-out Method for Training Machine Learning Models. <https://vitalflux.com/hold-out-method-for-training-machine-learning-model/>
- Kumar, D., Mathur, H. D., Bhanot, S., & Bansal, R. C. (2020). Forecasting of solar and wind power using LSTM RNN for load frequency control in isolated microgrid. *International Journal of Modelling and Simulation*. <https://doi.org/10.1080/02286203.2020.1767840>
- Levman, J., Jennings, M., Kabaria, P., Rouse, E., Nangaku, M., Berger, D., . . . Tyrrell, P. (2021). Hold-out validation for the assessment of stability and reliability of multivariable regression demonstrated with magnetic resonance imaging of patients with schizophrenia. *International Journal of Developmental Neuroscience*, 1-8. <https://doi.org/10.1002/jdn.10144>
- Li, P., Zhou, K., Lu, X., & Yang, S. (2019). A hybrid deep learning model for short-term PV power forecasting. *Applied Energy*, 259. <https://doi.org/10.1016/j.apenergy.2019.114216>.
- Liu, H., Gao, Q., & Pengcheng, M. (2021). Photovoltaic generation power prediction research based on high quality context ontology and gated recurrent neural network. *Sustainable Energy Technologies and Assessments*, 45. <https://doi.org/10.1016/j.seta.2021.101191>
- Liu, S., Hao, X., Meng, Z., Li, J., Cui, T., & Wei, L. (2021). Application of SRNN-GRU in Photovoltaic power Forecasting. *International Conference on Power System and Energy Internet (PoSEI2021)*. <https://doi.org/10.1051/e3sconf/202125602001>
- Massaoudi, M., Chihi, I., Sidhom, L., Trabelsi, M., Refaat, S. S., & Oueslati, F. S. (2019). Performance Evaluation of Deep Recurrent Neural Networks Architectures: Application

- to PV Power Forecasting. *2nd International Conference on Smart Grid and Renewable Energy, SGRE 2019 - Proceedings*.
- Mohandes, M., Rehman, S., & Halawani, T. (1998). Estimation of global solar radiation using artificial neural networks. *Renewable Energy*, 14, 179-184.
- Neelamegam, P., & Arasu Amirtham, V. (2016). Prediction of solar radiation for solar systems by using ANN models with different back propagation algorithms. *Journal of Applied Research and Technology*. 10.1016/j.jart.2016.05.001
- Olah, C. (2015). *Understanding LSTM Networks*. colah's blog.
<https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- ONU. (2022). *17 objetivos para transformar nuestro mundo*.
<https://www.un.org/sustainabledevelopment/es/>
- Palma-Behnke, R., Benavides, C., Lanas, F., & Severino, B. (2013). A Microgrid Energy Management System Based on the Rolling Horizon Strategy. *IEEE TRANSACTIONS ON SMART GRID*, 4(2).
- Pandey, C., & Katiyar, A. (2013). Solar Radiation: Models and Measurement Techniques. *Journal of Energy Hindawi*.
- Paredes, M. (2022). Diseño y construcción de un conversor DC-DC tipo flyback para seguimiento de punto de máxima potencia en aplicaciones fotovoltaicas. *Carrera de Ingeniería en Electrónica y Automatización. Escuela Politécnica Nacional EPN*.
<http://bibdigital.epn.edu.ec/handle/15000/22342>
- Peláez Samaniego, M. R., & Espinoza, A. J. (2015). Energía solar en el Ecuador. *Energía Renovables en el Ecuador. Situación actual, tendencias y perspectivas*.
- Rajagukguk, R., Ramadhan, R., & Lee, H. (2020). A Review on Deep Learning Models for Forecasting Time Series Data of Solar Irradiance and Photovoltaic Power. *Energies*.
<https://doi.org/10.3390/en13246623>

- Rivera-González, L., Bolonio, D., Mazadiego, L., & Valencia-Chapi, R. (2019). Long-Term Electricity Supply and Demand Forecast (2018–2040): A LEAP Model Application towards a Sustainable Power Generation System in Ecuador. *Sustainability*.
<https://doi.org/10.3390/su11195316>
- Rodriguez, M., Salazar, A., Arcos-Aviles, D., LLanos, J., Martínez, W., & Motoasca, E. (2021). A Brief Approach of Microgrids Implementation in Ecuador: A Review. *Recent Advances in Electrical Engineering, Electronics and Energy. CIT 2020. Lecture Notes in Electrical Engineering, 762*. https://doi.org/10.1007/978-3-030-72208-1_12
- Romero, A. F., Quilumba, F. L., & Arcos, H. N. (2017). Short-term active power forecasting of a photovoltaic power plant using an artificial neural network. *2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM)*, 1-5. 10.1109/ETCM.2017.8247527
- Sabri, M., & El Hassouni, M. (2022). A Novel Deep Learning Approach for Short Term Photovoltaic Power Forecasting Based on GRU-CNN Model. *The International Conference on Energy and Green Computing (ICEGC'2021)*, 336.
<https://doi.org/10.1051/e3sconf/202233600064>
- Schallenberg, J., & Piernavieja, G. (2008). *Energías renovables y eficiencia energética*. Instituto Tecnológico de Canarias, S.A.
- Schmerler, D., Velarde, J., Rodríguez, A., & Solís, B. (2019). *Energías renovables: experiencia y perspectivas en la ruta del Perú hacia la transición energética* (Primera ed.). Lima: Organismo Supervisor de la Inversión en Energía y Minería.
- Shyu, C.-W. (2019). Ensuring access to electricity and minimum basic electricity needs as a goal for the post-MDG development agenda after 2015. *Energy for Sustainable Development, 19*, 29–38. <https://doi.org/10.1016/j.esd.2013.11.005>
- Sodsong, N., Yu, K. M., & Ouyang, W. (2019). Short-Term Solar PV Forecasting Using Gated Recurrent Unit with a Cascade Model. *2019 International Conference on Artificial*

Intelligence in Information and Communication (ICAIC), 292-297.

10.1109/ICAIC.2019.8668970

Suresh, V., Janik, P., Rezmer, J., & Leonowicz, Z. (2019). Forecasting Solar PV Output Using Convolutional Neural Networks with a Sliding Window Algorithm. *energies*.

10.3390/en13030000

Terreros, M. (2017). Nuevos modelos de predicción a corto plazo de la generación eléctrica en plantas basadas en energía solar fotovoltaica. *Tesis doctoral, Departamento de Ingeniería Eléctrica. Universidad de La Rioja*.

The MathWorks Inc. (2022).

<https://la.mathworks.com/help/deeplearning/ref/nnet.cnn.layer.lstmprojectedlayer.html>

Toledo, M. A., Macancela, W. E., Aucapiña, F. F., Álvarez, C. M., & Morales, D. X. (2019).

Forecast of solar radiation with the application of neural networks in rural zones of Ecuador. *2019 FISE-IEEE/CIGRE Conference - Living the energy Transition*

(*FISE/CIGRE*), 1-6. 10.1109/FISECIGRE48012.2019.8984995

Vaca-Revelo, D., & Ordóñez, F. (2019). Mapa Solar del Ecuador 2019. *SCINERGY Research in Alternative Energy*.

Wang, K., Qi, X., & Liu, H. (2019). A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network. *Applied Energy*, 251.

<https://doi.org/10.1016/j.apenergy.2019.113315>

Wang, Y., Liao, W., & Chang, Y. (2018). Gated Recurrent Unit Network-Based Short-Term Photovoltaic Forecasting. *Energies*. <https://doi.org/10.3390/en11082163>

Zhang, R., Ma, H., Hua, W., Saha, T. K., & Zhou, X. (2020). Data-Driven Photovoltaic Generation Forecasting Based on a Bayesian Network With Spatial–Temporal Correlation Analysis. *IEEE Transactions on Industrial Informatics*, 1635-1644.

Apéndices