



**DISEÑO DE UN MODELO DE INTELIGENCIA ARTIFICIAL PARA PARA PREDECIR
LA ENERGÍA SOLAR PRODUCIDA**

Carlos Eduardo Báez Coronado

Informe de práctica para optar al título de Ingeniero Mecánico

Asesor Interno

Laura Isabel Velásquez García, Profesora Departamento de Ingeniería Mecánica

Asesor externo de la empresa Ceiba Software

Juan Fernando Sarmiento Garzón, Ingeniero Industrial

Universidad de Antioquia

Facultad de Ingeniería

Ingeniería Mecánica

Medellín, Antioquia, Colombia

2024

Referencia

C. E. Báez Coronado. *Diseño de un modelo de inteligencia artificial para predecir la energía solar producida 2023*. (Trabajo de grado profesional Ingeniería Mecánica). Universidad de Antioquía, Medellín, Colombia, 2024.



Centro de Documentación Ingeniería (CENDOI)

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

Rector: John Jairo Arboleda Céspedes.

Decano/Director: Julio César Saldarriaga.

Jefe departamento: Pedro León Simancas.

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Tabla de contenido

1.	Resumen	7
2.	Introducción	9
3.	Objetivos	10
3.1	Objetivo general.....	10
3.2	Objetivos específicos.....	10
4.	Marco teórico.....	11
5.	Metodología	20
6.	Desarrollo del problema	21
6.1	Recolección de los datos.	21
6.2	Preprocesamiento de los datos.	23
6.2.1	División de los datos en conjuntos de entrenamiento.	23
6.2.2	Tratamiento de los datos:	24
6.3	Selección del modelo	26
6.3.1	Modelo basado en rayos solares.....	26
6.3.2	Modelo basado en la nubosidad (Cloud-Based Model):.....	27
6.3.3	Redes neuronales recurrentes:.....	29
7.	Planteamiento del problema	30
7.1	Funcionamiento de la red de captación de energía solar	34
7.1.1	Paneles Solares.....	34
7.1.2	Regulador	38
7.1.3	Baterías:	40
7.1.4	Inversor	40
7.2	Entrenamiento de la red Neuronal:	41
7.2.1	Elección de las funciones de activación:.....	42
7.2.2	Funciones de activación	43
7.2.3	Inicialización de los pesos y valores del Bias:.....	44
7.2.4	Cálculo del error entre el valor predicho y el valor real.	45
8.	Resultados.	47
8.1	Modelo LSTM:	47
9.	Conclusiones	51
10.	Referencias.....	52

Lista de ilustraciones

Ilustración 1. Consumo global de combustibles fósiles. Tomado de: Energy Institute - Statistical Review of World Energy (2023); Smil (2017) – with major processing by Our World in Data. “Direct primary energy from natural gas” [dataset]. Energy Institute, “Statistical Review of World Energy”; Smil, “Energy Transitions: Global and National Perspectives” [original data].	12
Ilustración 2. Comparación de muertes generadas por Twh entre diferentes métodos de producción.....	13
Ilustración 3. Comparación de la energía producida mediante diferentes métodos a lo largo de los últimos años.....	14
Ilustración 4. Distribución de la producción de energía eléctrica en Colombia desde el año 2000.	15
Ilustración 5. Capas iniciales de salida de una red neuronal. Tomado de PytorchRevelio, https://github.com/farhad-dalirani/PytorchRevelio	17
Ilustración 6. Extracción de características más importantes de las imágenes. Tomado de PytorchRevelio, https://github.com/farhad-dalirani/PytorchRevelio	18
Ilustración 7. Visualización del funcionamiento de las redes neuronales recurrentes.	19
Ilustración 8. Flujo del trabajo para la construcción del modelo.	21
Ilustración 9. Área de recolección de los datos principales para el entrenamiento del modelo. ..	22
Ilustración 10. Esquema gráfico de la división de los datos de entrenamiento, testeo y validación.	24
Ilustración 11. Comportamiento promedio de la potencia generada en un día	29
Ilustración 12. Comportamiento promedio de la radiación durante un año.	30
Ilustración 13. Comparación de los datos estadísticos con datos diarios y mensuales.	31
Ilustración 14. Imagen tomada de Predicting the Price of Crude Oil and its Fluctuations Using Computational Econometrics: Deep Learning, LSTM, and Convolutional Neural Networks - Scientific Figure on ResearchGate. Available from: https://www.researchgate.net/figure/Classical-k-fold-cross-validation-vs-time-series-split-cross-validation_fig1_355889701 [accessed 25 Nov, 2023]	33
Ilustración 15. Características y dimensiones de los paneles solares.....	35
Ilustración 16. Ilustración gráfica de un montaje de paneles solares con conexión en paralelo	37
Ilustración 17. Características de los reguladores de energía.....	39
Ilustración 18. Esquema ilustrativo del proceso de merge realizado en los datasets.	41
Ilustración 19 Esquema del funcionamiento de un perceptrón.	43
Ilustración 20. Funciones de activación de la red neuronal.	44
Ilustración 21. Flujo matemático de operaciones entre dos neuronas.	44
Ilustración 22. Rendimiento del modelo LSTM durante el entrenamiento y validación, con periodo de tiempo de un día.....	48
Ilustración 23. Comparación realizada entre los datos predichos y reales durante un año.	49

Lista de tablas

Tabla 1. Descripción estadística de las características del Dataset.....	25
Tabla 2. Tabla de correlaciones con la variable objetivo.....	26
Tabla 3. Variación en la magnitud de la radiación a lo largo del día.....	38



Siglas, acrónimos y abreviaturas

RRN	Red neuronal recurrente.
Dataset	Conjunto de datos utilizados para el entrenamiento del modelo.
Bias	Valor numérico usado para ajustar la salida de una red neuronal
IA	Inteligencia Artificial
Perceptrón	Mínima unidad funcional en una red neuronal
MSE	Error cuadrático medio
MAPE	Error absoluto medio
DNN	Red Neuronal Densa
MAPE	Error absoluto medio

1. Resumen

El semestre de industria fue realizado en la empresa Ceiba Software House SAS, reconocida por brindar soluciones tecnológicas en el sector energético, aportando con proyectos relacionados con la transformación del sector energético, con sede en la ciudad de Medellín. Actualmente, ha firmado contratos con empresas reconocidas a nivel nacional como EPM y XM con sistemas de planificación energética a corto y largo plazo para ofrecer un escenario energético sostenible.

El sector energético depende en gran parte de las fuentes de energía no renovables, que generan un impacto negativo en el medio ambiente. Para reducir al máximo estos problemas, una de las grandes tendencias tecnológicas en los últimos años ha sido el desarrollo de nuevos métodos de generación energética enfocados en la transición hacia el uso de energías renovables que permitan reducir el impacto ambiental y crear escenarios energéticos sostenibles a largo y corto plazo. Sin embargo, uno de los grandes problemas de estas nuevas tecnologías es la dependencia que tienen con los factores climáticos del ambiente en donde están ubicadas. La disponibilidad del viento, radiación solar o precipitaciones pueden variar a lo largo del año dependiendo de su ubicación geográfica, siendo más marcado este cambio si hay estaciones climáticas en el sector donde se instalan.

Esta dependencia climática condiciona la productividad de los sistemas de generación de energía renovables, siendo necesario la implementación de un análisis detallado de los patrones climáticos y ubicación de las instalaciones. Otro problema relacionado con esta transición es que la integración de estas nuevas tecnologías en los sectores de generación, transporte, industria y construcción implica una transformación en la infraestructura existente. Por tanto, se deben establecer estándares de calidad y confiabilidad para garantizar la seguridad y eficiencia de los sistemas renovables. Para garantizar estos factores de deben implementar herramientas de monitoreo y control, al igual que la capacitación y certificación de profesionales en el sector.

La digitalización cumple un papel importante durante la integración de las energías renovables, gracias a que la recopilación y análisis de datos en tiempo real permite una gestión más eficiente de los recursos energéticos para facilitar el funcionamiento de los equipos generadores de energía. La inteligencia artificial y la minería de datos son herramientas clave en este sentido ya



que permiten identificar patrones, predecir la generación de energía y optimizar el rendimiento de los sistemas renovables.

La transición hacia las energías renovables requiere considerar factores como la variabilidad climática, integración en distintos sectores y la implementación de nuevas tecnologías digitales. Con un enfoque adecuado en estos aspectos, es posible maximizar los beneficios de las energías renovables y avanzar a un futuro más sostenible.

Palabras clave: Energía Solar, Energías renovables, Inteligencia Artificial, Análisis de datos, Predicción energética, Forecasting Solar Energy, Solar Energy Prediction.

2. Introducción

El cambio climático ha afectado significativamente las condiciones ambientales naturales, por lo que las políticas internacionales se centran en el uso eficiente de la energía. En este contexto, el diseño de sistemas de aire acondicionado, ventilación y calefacción busca optimizar el consumo energético. En los próximos años se tiene previsto la conexión de una mayor cantidad de objetos conectados a la red eléctrica. Estos componentes, dependiendo de su aplicación, pueden generar energía y suministrarla a la red eléctrica, consumir grandes cantidades de energía de manera simultánea, o también estar conectados al circuito eléctrico sin que las empresas que suministran energía estén al tanto. Estas nuevas dinámicas generan desafíos en la estabilidad y rendimiento de la red, dando como resultado desequilibrios, reflejándose en cambios de frecuencia, apagones o sobrecargas de capacidad en la red de distribución.

Para gestionar eficientemente los sistemas de energía que cada vez se vuelven más complejos, es necesario contar con datos en tiempo real, análisis avanzados y automatización. En el caso del proyecto propuesto, se realizará un enfoque en la implementación de un algoritmo de predicción de la energía solar disponible.

Para la implementación de modelos de inteligencia artificial en el suministro de energía es necesario contar con datos en tiempo real sobre la generación de energía, y también la configuración de la red eléctrica. El problema de la integración de estos modelos radica en la carencia de los aspectos mencionados anteriormente, la falta de datos en tiempo real dificulta la toma de decisiones estratégicas, la identificación de problemas potenciales y también el desarrollo y puesta en marcha de decisiones estratégicas. La complejidad de los sistemas de energía aumentará la probabilidad de desequilibrios, apagones y sobrecargas, generando redes eléctricas inestables.

La mejor manera de afrontar estos problemas de crecimiento y aumento de complejidad en las redes es mediante la implementación de tecnologías como el uso de modelos de aprendizaje computacional, que permiten el monitoreo en tiempo continuo de las redes, predicción de fallas y desequilibrios, ofreciendo la posibilidad de generar acciones preventivas para garantizar un rendimiento óptimo de los sistemas, de esta manera se podrá gestionar de manera eficiente la

creciente cantidad de activos conectados a la red y asegurar un suministro de energía confiable y sostenible.

3. Objetivos

3.1 Objetivo general

- Diseñar un modelo de inteligencia artificial para realizar un análisis predictivo de la energía generada basado en las condiciones ambientales y geográficas de su instalación.

3.2 Objetivos específicos

- Construir un modelo de aprendizaje supervisado a partir de los datos energéticos solares disponibles de manera libre en internet.
- Investigar y documentar los modelos predictivos convencionales que han sido utilizados, y determinar cuáles son las limitaciones que presentan en comparación con los modelos predictivos de inteligencia artificial.
- Explorar las arquitecturas de modelos de inteligencia artificial utilizados para la predicción de la energía solar producida, y evaluar el desempeño con los datos obtenidos realizando una predicción a largo plazo.
- Realizar un análisis exploratorio de los conjuntos de datos utilizados y extraer las características más relevantes para predecir el comportamiento de la energía solar.
- Implementar técnicas de minería de datos para aumentar la riqueza de los Datasets utilizados para la construcción del modelo, junto con la evaluación de la calidad de sus datos para lograr un modelo con buen desempeño.
- Investigar los componentes principales de los sistemas de extracción de energía solar, junto con el análisis de las características más importantes para tener en cuenta durante la instalación y puesta en marcha de los equipos.

4. Marco teórico

La producción de energía —principalmente la quema de combustibles fósiles— es responsable de alrededor de tres cuartos de las emisiones mundiales de gases de efecto invernadero. La quema de estos combustibles fósiles presenta un alto costo para la salud humana, por lo menos 5 millones de muertes son atribuidas a la contaminación ambiental cada año (Hannah Ritchie & Pablo Rosado, 2020).

La quema de combustibles fósiles a gran escala como método de generación energética tuvo como punto de inicio la revolución industrial, teniendo en cuenta la información suministrada por Vaclav Smil (Vaclav Smil, 2017) a partir de mediados del siglo 20, la cantidad de energía ha incrementado de una manera descontrolada, generando en algunas épocas un incremento de hasta el doble de demanda comparado con décadas inmediatamente anteriores. Los combustibles fósiles que son utilizados para la generación se pueden dividir en tres componentes principales, gas, petróleo y carbón. A pesar de las consecuencias negativas del uso de estos combustibles, hoy el uso del gas y del petróleo siguen aumentando, mientras que el carbón está siendo reducido. Este comportamiento se encuentra corroborado por los datos obtenidos por el instituto de energías (Energy Institute, 2023), cuyos datos e imágenes se pueden usar libremente y cuyo comportamiento se muestra en la ilustración 1.

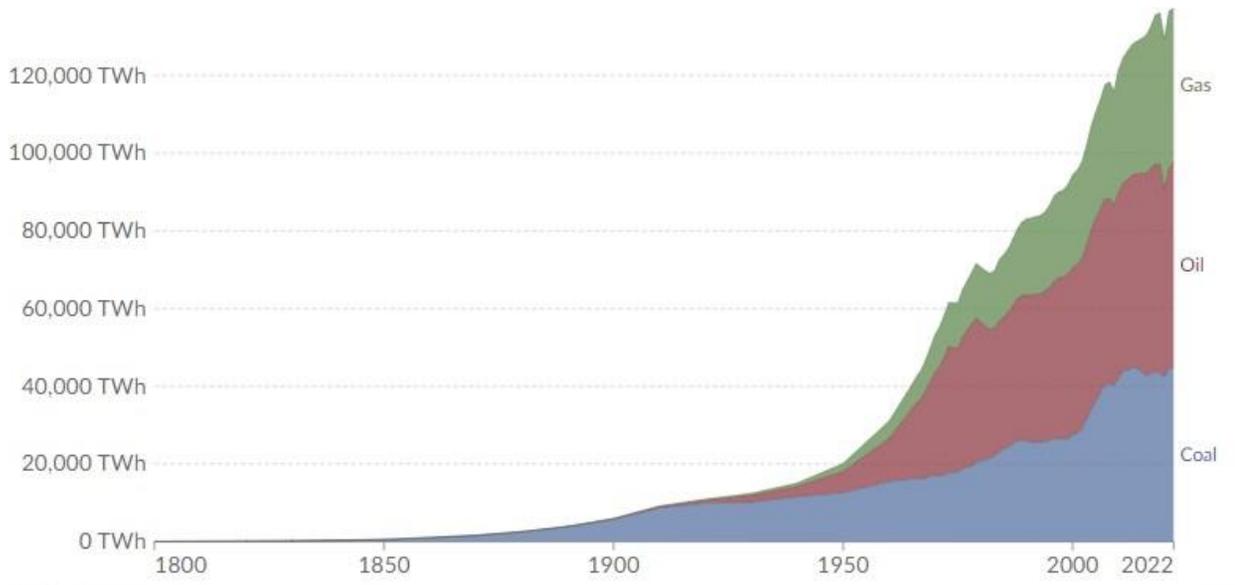


Ilustración 1. Consumo global de combustibles fósiles. Tomado de: Energy Institute - Statistical Review of World Energy (2023); Smil (2017) – with major processing by Our World in Data. “Direct primary energy from natural gas” [dataset]. Energy Institute, “Statistical Review of World Energy”; Smil, “Energy Transitions: Global and National Perspectives” [original data].

A pesar de las grandes ventajas, amplia explotación y la baja dificultad de producción energética ligada al uso de energías no renovables, presentan impactos negativos a nivel ambiental y también en la salud de los humanos y seres vivos. Tomando los datos publicados por Sovacool et al. (2016); and Markandya, A., & Wilkinson, P. (2007), en el Dataset de “Deaths per-TWh energy production”. Se encuentra las principales causas de Muerte:

- **Aire contaminado:** La quema de los combustibles fósiles, junto con la quema de la biomasa son los principales factores que causan muertes prematuras en los seres humanos.
- **Accidentes:** Están incluidos los accidentes durante la extracción y procesamiento de los combustibles, por ejemplo, carbón, uranio, petróleo, etc. Y también durante la construcción, operación y mantenimiento de la planta de producción energética.

- Gases de efecto invernadero:** Los combustibles fósiles son la principal fuente generadora de gases efecto invernadero, relacionados con el aumento de la temperatura global, provocando la elevación de la temperatura en el planeta.

A partir de los datos mencionados anteriormente relacionados con las muertes generadas por los diferentes métodos de producción energética, se elaboró una gráfica para ilustrar la tasa de muertes por Twh producidos, encabezando la lista los combustibles fósiles, tomando la mayor fracción de las muertes los productos relacionados con el carbón y el petróleo, mientras que los otros métodos de producción energéticos están muy alejados de estas cifras.

En la ilustración 2, se observa que los métodos de energías renovables presentan muertes insignificantes en comparación con los combustibles fósiles, lo que afirma que además de ser los medios más limpios de producción energética, son los más seguros.

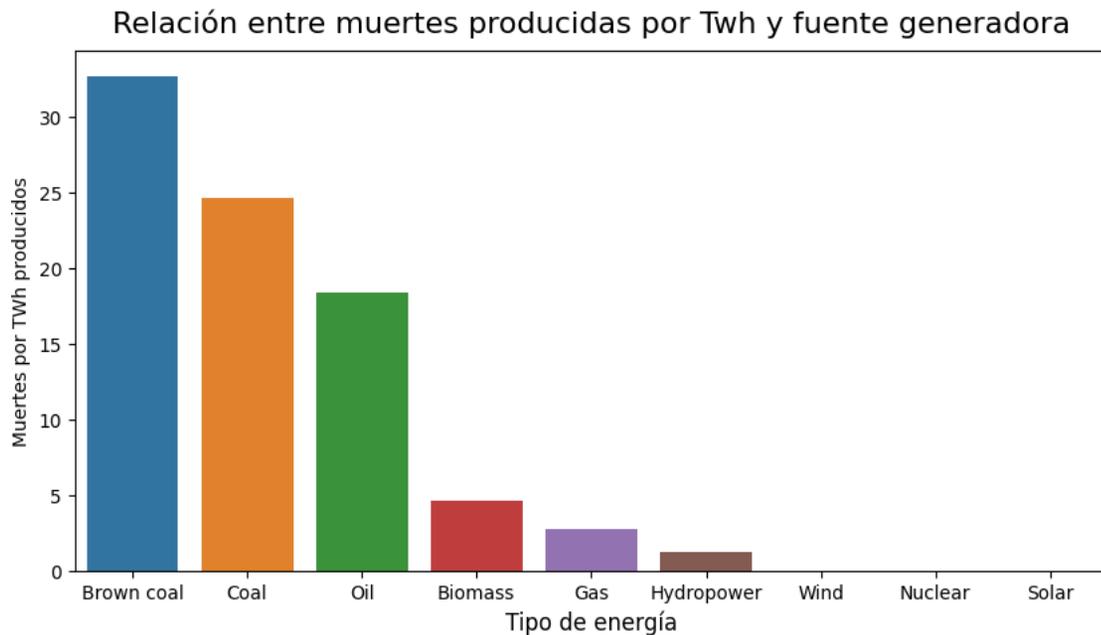


Ilustración 2 Comparación de muertes generadas por Twh entre diferentes métodos de producción.

Tendencias energéticas mundiales.

En los últimos años ha tomado importancia la conservación del medio ambiente, y la búsqueda de métodos de producción de energía que reduzcan los gases de efecto invernadero generados por los métodos de producción convencionales. En este trabajo se limitó el alcance solo a los medios de producción eléctrica para comparar con mayor facilidad entre diferentes medios de producción.

Hoy en día, a nivel global el carbón y el gas natural constituyen la mayor fuente de producción de energía eléctrica, seguida por la energía hidroeléctrica. Tanto el carbón como el gas natural han tomado el liderazgo desde las primeras estimaciones de producción. Tomando los datos publicados por Ember en el Dataset de “Yearly Electricity Data (2023)”, a partir del año 2010 las fuentes de energías renovables empezaron a tomar una mayor importancia en la producción energética global, situándose la energía solar y eólica por encima de la energía proveniente del petróleo. La energía hidroeléctrica ha remplazado a la del gas natural, mientras que la generada por el carbono se ha mantenido en un lamentable crecimiento constante.

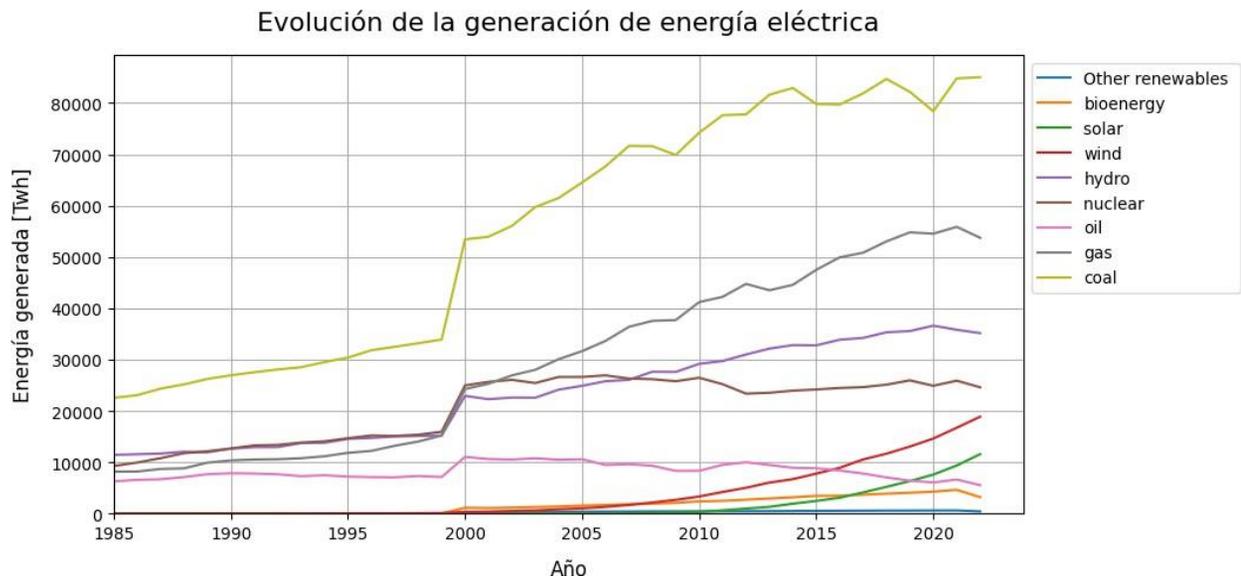


Ilustración 3 Comparación de la energía producida mediante diferentes métodos a lo largo de los últimos años.

Reduciendo el análisis de los datos, y analizando específicamente el caso de Colombia, se puede observar que no sigue la tendencia mundial de consumo por tipo, sino que las principales fuentes energéticas, según el registro de los datos a partir de 1985, el principal método de obtención energética proviene de recursos Hidroeléctricos, generando aproximadamente un 80% de la energía, seguido por el consumo de Gas Natural y Carbón. A pesar del consumo a nivel nacional de recursos hidroeléctricos, la incursión en otros tipos de energías renovables es muy baja o despreciable, por ejemplo, aunque la energía eléctrica producida a partir del petróleo tiene una pequeña parte, supera a la solar y eólica.

La comparación de estos métodos de generación energética a nivel nacional se muestra en la siguiente ilustración:

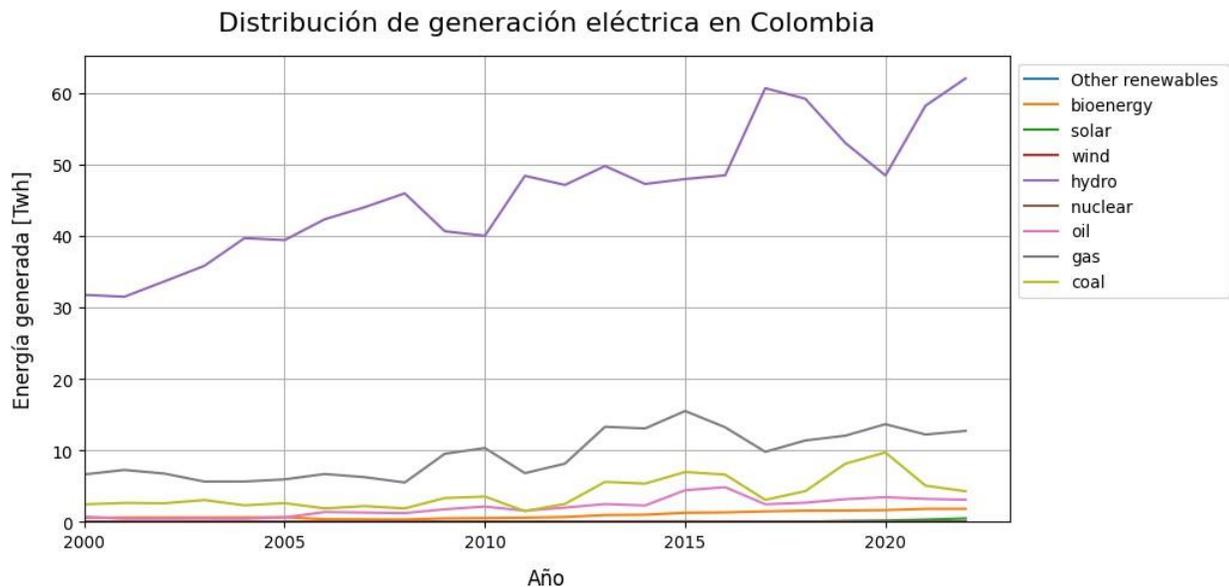


Ilustración 4 Distribución de la producción de energía eléctrica en Colombia desde el año 2000.

Redes Neuronales.

Desde hace mucho tiempo, se ha generado un paradigma sobre el funcionamiento del cerebro humano, que ha tomado gran fuerza gracias a la nueva tendencia tecnológica conocida como inteligencia artificial, para asemejar el comportamiento del cerebro humano mediante algoritmos computacionales.

En 1943, se registraron los primeros intentos por elaborar una red neuronal que se asemejara al funcionamiento del cerebro humano por medio de las RNA, por parte de Warren McCulloch y Walter Pitts. Este modelo intentaba simular la lógica de operaciones binarias que ejecutan las neuronas del cerebro humano. Más adelante, tomando como base estos adelantos, se creó un modelo conocido como el perceptrón (Fausett, 1994; Haykin, 1999; Olmsted, 1998), cuyo modelo matemático tenía la capacidad de memorizar un conjunto de valores de entrada. Los valores numéricos de la red neuronal se hallaron con la premisa propuesta por Frank Rosenblat, de que, si un problema que ingresaba a la red neuronal tenía solución, entonces, deben existir ciertos valores en la red que reproduzcan los utilizados durante el entrenamiento, que permitirá hallar la solución en un número finito de iteraciones. Después, estos conceptos básicos se usaron para extender el entrenamiento a múltiples capas de perceptrones, alcanzando millones de parámetros.

En 1991, el investigador Jürgen Schmidhuber diseñó una red de cientos de perceptrones mediante el uso de una técnica conocida como “entrenamiento no supervisado”, en donde la red debía por sí misma hallar los valores óptimos de sus parámetros, sin utilizar valores que indicaran los resultados correctos de la clasificación.

En el año 2004, el Instituto Canadiense para la Investigación Avanzada con el apoyo de Yann LeCun y Yoshua Bengio fundó el programa “Neural Computation and Adaptive Perception”, compuesto por un grupo de científicos que realizaron un gran avance del concepto de Deep Learning, creando modelos matemáticos que tuvieran un desempeño aproximado al funcionamiento del cerebro.

Para ilustrar mejor el funcionamiento de una red neuronal, se dará un ejemplo de una arquitectura especializada en el reconocimiento de imágenes. A grandes rasgos, el funcionamiento de las redes neuronales es el siguiente:

En las partes tempranas de la red, las neuronas se encargan de extraer las características de una imagen, como la textura, los bordes, transiciones de color, formas, etc. Cada capa de la red neuronal contiene unos filtros que se aplicarán a la imagen (operaciones matriciales), cada filtro extrae algunas características que se entregarán a las capas siguientes. Algunas de las características que pueden extraer estos tipos de redes se encuentran en la siguiente ilustración:

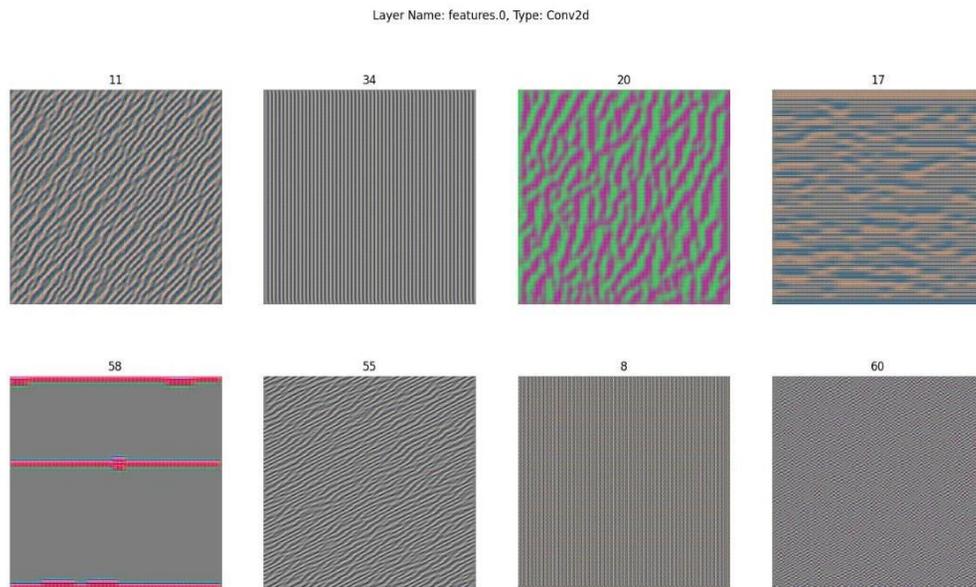


Ilustración 5 Capas iniciales de salida de una red neuronal. Tomado de PytorchRevelio, <https://github.com/farhad-dalirani/PytorchRevelio>.

En las primeras capas de la red se aprenden las características más generales, generalmente asociadas a las geometrías. Dependiendo de la arquitectura de la red seleccionada, cada vez se vuelve más profunda, cada vez más complejas y se especializan en las características más notables de cada clase, como, por ejemplo, la nariz de una persona, los ojos, manos, pies, y demás

características notables de las clases. Entre más capas tenga la red, mayores características de la imagen podrán ser extraídas, lo que explica la tendencia en los algoritmos de aprendizaje profundo de aumentar el número de capas para mejorar el rendimiento entregado por estos modelos. Las activaciones producidas por las imágenes en las capas más profundas de la red están en la siguiente ilustración, donde se puede observar que las activaciones corresponden a las características más notables de cada clase, como en el pavorreal, que se centran en los cambios de color del plumaje, y en el caso del zorro en la boca y las orejas.



Ilustración 6 Extracción de características más importantes de las imágenes. Tomado de PytorchRevelio, <https://github.com/farhad-dalirani/PytorchRevelio>.

Aunque la implementación de las redes neurales profundas puede ayudar al modelo a desempeñarse mejor en las tareas que realiza, ya que pueden extraer características cada vez más complejas, presentan problemas durante su entrenamiento, donde lo más importante es la degradación que se presenta durante el entrenamiento de la red, pues afecta al entrenamiento de las capas más profundas de la red, dificultando la optimización de los parámetros esta.

Redes neuronales recurrentes:

Las redes neuronales recurrentes tienen una arquitectura especializada para trabajar con la dependencia temporal de los datos. Por ejemplo, dados los siguientes tiempos $[t_{t-3}, t_{t-2}, t_{t-1}]$ se necesita obtener el valor para el tiempo t , en este caso para realizar la predicción, la red neuronal se fija en las predicciones anteriores para producir la siguiente salida, este concepto es conocido como recurrencia.

En la ilustración 7 se muestra a grandes rasgos la dinámica utilizada por estas redes, por ejemplo, suponga que se va a realizar la predicción para el tiempo t , en este caso, como parámetros de entrada a la neurona, llegan las observaciones del tiempo, que para la predicción solar serían parámetros equivalentes a Temperatura, radiación, hora, nubosidad, etc. Y adicionalmente llega otra entrada que es la predicción realizada por la neurona anterior, que a su vez tendrá dentro de sí las predicciones de las neuronas anteriores, generando un patrón recurrente en las predicciones.

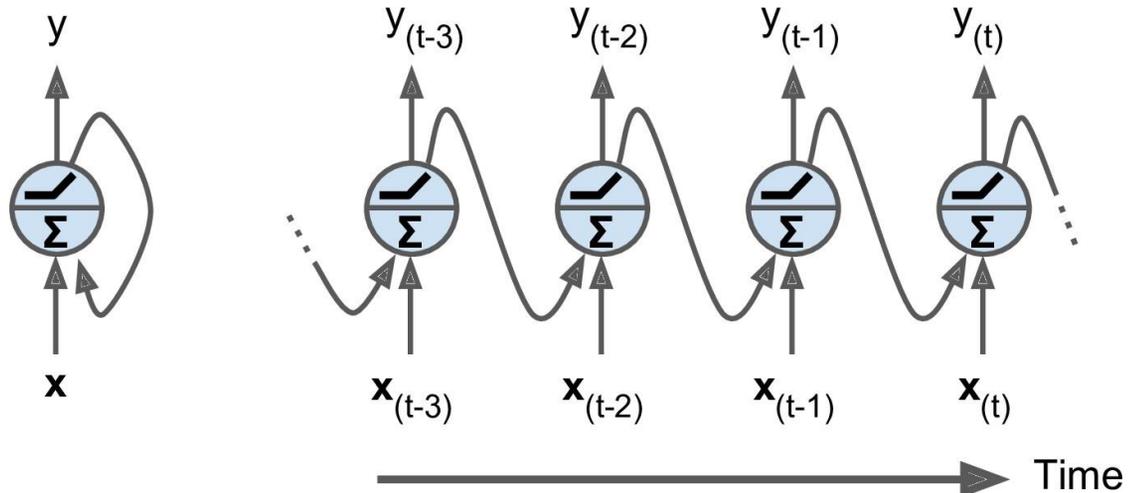


Ilustración 7 Visualización del funcionamiento de las redes neuronales recurrentes.

5. Metodología

El desarrollo de este trabajo bajo la modalidad de Semestre de industria se llevará a cabo mediante las siguientes fases para cumplir con los objetivos planteados.

- **Recopilación de datos:** Se recopilarán datos históricos de generación de energía solar, así como datos meteorológicos relevantes, como la radiación solar, la temperatura y la humedad. Estos datos se utilizarán como conjunto de entrenamiento para los modelos de inteligencia artificial.
- **Preprocesamiento de datos y selección de características:** Los datos recopilados se preprocesarán para eliminar cualquier ruido o inconsistencia. Además, se realizará una exploración y análisis de los datos para identificar posibles correlaciones y patrones. Se utilizarán técnicas de minería de datos para seleccionar las características más relevantes para la predicción de la generación de energía solar. Esto ayudará a reducir la dimensionalidad de los datos y mejorar la eficiencia de los modelos de inteligencia artificial.
- **Comparación y selección del modelo:** Se probarán diferentes modelos de inteligencia artificial y modelos teóricos, como redes neuronales y ecuaciones clásicas para encontrar el modelo que mejor se ajuste a los datos. Se utilizarán técnicas de validación cruzada para evaluar y comparar el rendimiento de los modelos.

6. Desarrollo del problema

El flujo que se siguió para el desarrollo del problema se encuentra graficado en la ilustración 8, cuya explicación a detalle será dada a lo largo del documento:

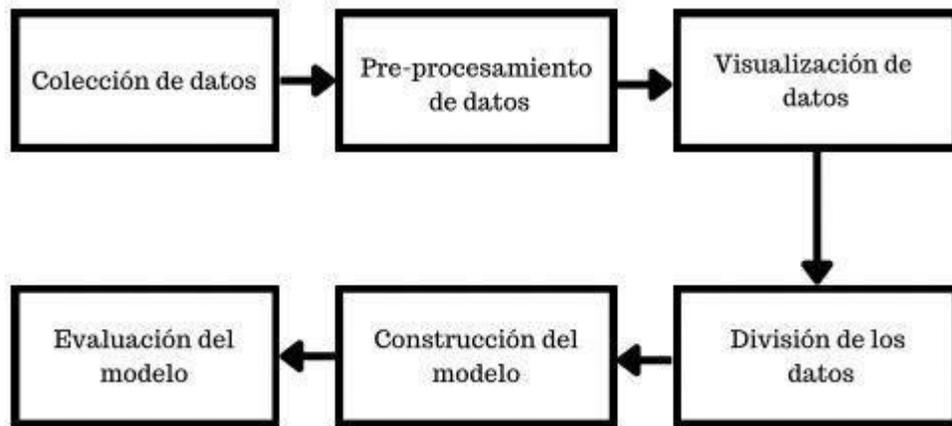


Ilustración 8. Flujo del trabajo para la construcción del modelo.

6.1 Recolección de los datos.

Tal como se había mencionado anteriormente, la calidad de los datos con los cuales va a ser entrenado el modelo es de vital importancia, dado que de su información va a ser generado el modelo, y este hallará las relaciones que tienen los datos entre sí, junto con la importancia de su secuencia temporal.

En este estudio se utilizaron 7 Datasets distintos, cuyos enlaces se encuentran en los anexos, junto al repositorio de GitHub de este proyecto.

La mayor cantidad de datos fueron extraídos de la página web del laboratorio nacional de energía renovable, denotado por sus siglas como NREL (<https://www.nrel.gov/>). A partir de él se consiguieron los datos de una planta generadora de energía solar, y también los datos desde el año 1998 hasta el año 2023 para estados unidos y américa. En cuanto a las tendencias energéticas

globales y nacionales, los datos fueron extraídos de las bases de datos del instituto de energías (Statistical Review of World Energy, 2023). Otros datos complementarios, que fueron utilizados con el propósito de brindar un contexto introductorio a la problemática fueron extraídos de Sovacool et al. (2016); y Markandya, A., & Wilkinson, P. (2007)

También se complementó el trabajo con la búsqueda de los datos disponibles entregados por la página web de la nasa de Power Larc (<https://power.larc.nasa.gov/>). En estos datos se consultó la información disponible en el área de Colombia, tal como se muestra en la ilustración 9.

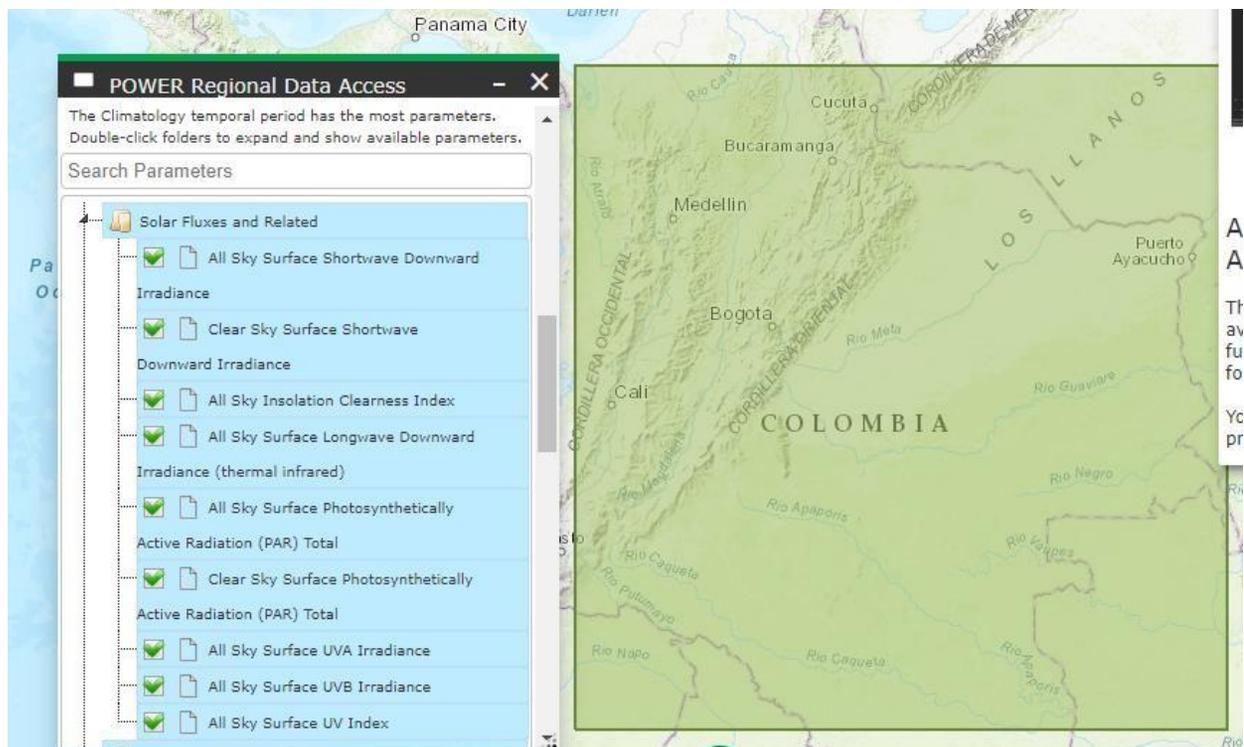


Ilustración 9. Área de recolección de los datos principales para el entrenamiento del modelo.

6.2 Preprocesamiento de los datos.

6.2.1 División de los datos en conjuntos de entrenamiento.

Una buena práctica de organización de los datos para poder medir la precisión de las predicciones realizadas por el modelo es dividir los datos en tres diferentes conjuntos, los cuales se explican a continuación:

- **Conjunto de entrenamiento:** Esta es la colección más grande de los datos, consiste en aproximadamente el 80% de los datos totales, a partir de estos datos se realiza el procedimiento iterativo de entrenamiento del modelo para poder ajustar los valores numéricos internos que van a componer el modelo predictivo
- **Conjunto de desarrollo:** Con este conjunto se valida el rendimiento del modelo después de cada iteración, la red neuronal no tiene acceso a estos datos durante el entrenamiento, solo se utilizan como validación después de cada iteración para poder validar si los parámetros de la red neuronal han sido correctamente definidos.
- **Conjunto de testeo:** Estos datos se utilizan una vez se ha entrenado totalmente la red neuronal y se valida que el rendimiento en los datos de desarrollo ha sido correcto, una vez el modelo consiga un buen rendimiento con estos datos, está listo para poder ser desplegado a producción

Esta división de los datos está graficada en la ilustración 10, donde se observa la prevalencia en cuanto a cantidad de datos de entrenamiento, más no en importancia, ya que el modelo no estará restringido solo a los datos de entrenamiento, sino que también hay que hacer pruebas para verificar que el comportamiento concuerda con los resultados esperados.

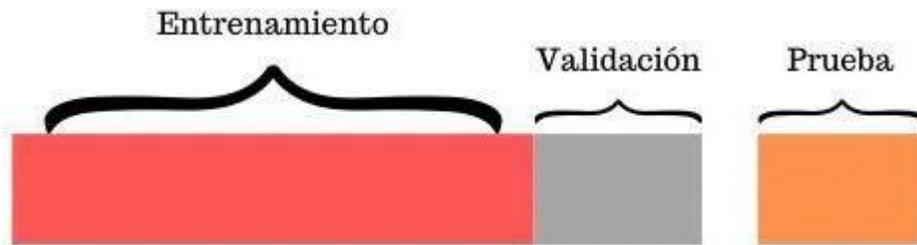


Ilustración 10. Esquema gráfico de la división de los datos de entrenamiento, testeo y validación.

6.2.2 Tratamiento de los datos:

Para tener un modelo con buen desempeño, es recomendable aplicar un tratamiento previo a los datos con los que se entrenará el modelo, dado que las categorías de variables están en rangos distintos.

La normalización se aplica para escalar todos los datos, de tal manera que las fluctuaciones que tengan las variables no afecten tanto a las demás, por ejemplo, los cambios de la radiación solar pueden subir hasta varios miles, mientras que la visibilidad varía entre 1 a 10. Cuando no se aplica un correcto normalizado a estas variables, el modelo tiende a sesgar sus predicciones por la variable que presenta la mayor diferencia, dando poca prioridad a aquellas que presentan fluctuaciones bajas, sin ser necesariamente, menos importantes.

En la tabla 1 se dan a conocer las características del Dataset, en donde se pone en evidencia la prevalencia de los cambios en algunas variables comparadas con otras. En esta table se exponen los datos en magnitud y no con sus respectivas unidades, dado que, al ser ingresadas al modelo, no se tienen en cuenta sus unidades de medida.

Tabla 1 Descripción estadística de las características del Dataset.

Datos estadísticos de variables principales							
	DHI	DNI	Dew Point	Surface Albedo	Wind Speed	Relative Humidity	Temperature
count	8760	8760	8760	8760	8760	8760	8760
mean	54.55901826	244.464384	-0.63490868	0.312575342	3.307317352	56.9875879	9.091118721
std	83.41404087	352.882949	8.47535412	0.228334959	1.860539599	22.41695088	12.64756014
max	479	1048	17.8	0.8	13.1	100	41.2

Para realizar la normalización de los datos, a cada valor se le resta la media de la columna a la cual pertenece, y seguidamente el resultado se divide en la desviación estándar de la columna, este procedimiento está descrito por la siguiente ecuación tomada de (Gerón. A, 2019):

$$N_i = \frac{(X_i - \mu)}{\sigma} \quad Ec. (1).$$

En donde:

- μ : media de la característica i .
- σ : Desviación estándar de la característica i .
- X_i : Dato i -ésimo asociado a la característica i .

Un factor importante para considerar en un modelo predictivo es la selección de las variables que se van a utilizar para predecir la característica deseada. Se recomienda realizar un análisis de correlaciones para seleccionar las variables con dependencia con el valor deseado. Cuando se incluyen variables con correlaciones altas, se espera que el modelo se pueda ajustar con una buena precisión a los datos, ajustándose exitosamente al comportamiento de ellos. En la tabla 2 se muestran las correlaciones entre las variables del Dataset y la columna a predecir, la cuál es ALLSKY_SFC_SW_DOWN.

Tabla 2. Tabla de correlaciones con la variable objetivo.

Parametros	Descripción	Correlación
QV2M	MERRA-2 Specific Humidity at 2 Meters (g/kg)	-0.12
RH2M	MERRA-2 Relative Humidity at 2 Meters (%)	-0.36
PRECTOTCORR	MERRA-2 Precipitation Corrected (mm/day)	-0.39
ALLSKY_SFC_SW_DWN	CERES SYN1deg All Sky Surface Shortwave Downward Irradiance (kW-hr/m ² /day)	1
CLRSKY_SFC_SW_DWN	CERES SYN1deg Clear Sky Surface Shortwave Downward Irradiance (kW-hr/m ² /day)	0.25
ALLSKY_KT	CERES SYN1deg All Sky Insolation Clearness Index (dimensionless)	0.98
ALLSKY_SFC_PAR_TOT	CERES SYN1deg All Sky Surface PAR Total (W/m ²)	0.99
TS	MERRA-2 Earth Skin Temperature (C)	0.31
PS	MERRA-2 Surface Pressure (kPa)	0.11
ALLSKY_SFC_LW_DWN	CERES SYN1deg All Sky Surface Longwave Downward Irradiance (W/m ²)	-0.13
CLRSKY_SFC_PAR_TOT	CERES SYN1deg Clear Sky Surface PAR Total (W/m ²)	0.26
ALLSKY_SFC_UVA	CERES SYN1deg All Sky Surface UVA Irradiance (W/m ²)	0.94
ALLSKY_SFC_UVB	CERES SYN1deg All Sky Surface UVB Irradiance (W/m ²)	0.9
ALLSKY_SFC_UV_INDEX	CERES SYN1deg All Sky Surface UV Index (dimensionless)	0.9
T2MDEW	MERRA-2 Dew/Frost Point at 2 Meters (C)	-0.09
WS2M	MERRA-2 Wind Speed at 2 Meters (m/s)	0.13

6.3 Selección del modelo

Antes del auge de las aplicaciones computacionales para el análisis y predicción de los datos, la cantidad de irradiación producida se medía mediante modelos empíricos que obtenía los datos climáticos con instrumentos ubicados en distintas posiciones a lo largo de un terreno. Los modelos más famosos son los siguientes:

6.3.1 Modelo basado en rayos solares.

Conocido en inglés como Sunshine-Based model utiliza los datos de la duración de los rayos solares y los cielos limpios como parámetros para predecir la radiación solar en cualquier momento del día. Es muy utilizado para calcular el promedio de radiación producida durante un mes. La ecuación para calcular el promedio de radiación solar producida en un día está dada por la

ecuación 2, tomada de (Sedai, A., Dhakal, 2023), cuyos significados de las variables se explican más abajo:

$$\frac{H}{H_0} = a + b \left(\frac{S}{S_0} \right) \text{ Ec. (2).}$$

A pesar de la popularidad de este modelo, tiene falencias dado que no tiene la capacidad para predecir la radiación solar cuando hay presencia de nubes en el cielo y también otras dependencias climáticas. Los coeficientes a y b varían a lo largo de la posición en el globo, por tanto, se requiere tomar medidas para poder obtenerlos, que puede acarrear costos adicionales generados por la adquisición de instrumentos de medida y personal.

6.3.2 Modelo basado en la nubosidad (Cloud-Based Model):

El fenómeno atmosférico más limitante para la predicción de la energía solar es la presencia de nubes en el cielo. Al recolectar datos satelitales de la presencia de nubes e identificar los patrones de estas, se diseñó un modelo predictivo para solventar la dificultad del modelo basado en la radiación solar. En este modelo ya no se tienen restricciones geográficas y no se requieren instrumentos para las mediciones de radiación solar.

Este modelo esta dado por las ecuaciones que se muestran más adelante, extraídas de (Sedai, A., Dhakal), en donde primero es necesario hallar el valor de la radiación difusa horaria, la cual está descrita por la ecuación 3.

$$I_b = 3.422[1 - e^{-0.0075(90-\theta)}] \text{ Ec. (3).}$$

Seguidamente, se halla el valor de la radiación de haz horario, que se encuentra en la ecuación 4.

$$I_d = 0.00913 + 0.00125(90 - \theta) + 0.723 - CF \text{ Ec. (4).}$$

Una vez los dos valores anteriormente descritos se han hallado, la radiación difusa promedio se puede hallar al realizar unas integraciones respecto al tiempo, siguiendo las operaciones plasmadas en la ecuación 5.

$$H = (1 - CF) \int_{Sunrise}^{Sunset} I_b(\theta) \times \cos(\theta) dt + \int_{Sunrise}^{Sunset} I_d(\theta) dt \quad Ec. (5).$$

El significado de las variables de las ecuaciones anteriores es el siguiente:

- H : Radiación diaria promedio.
- I_d : Radiación difusa horaria.
- I_b : Radiación de haz horario.
- CF : Factor de nubosidad.
- θ : ángulo cenit solar.
- H_o : Radiación promedio extraterrestre.
- a : Latitud.
- b : Coeficiente de correlación.

Sin embargo, a pesar de las ventajas que ofrece este modelo en comparación con otros, no ha sido muy utilizado últimamente debido a los altos costos que acarrea obtener los parámetros necesarios para su funcionamiento, y también la predicción de la radiación a largo plazo tiene un mal rendimiento, siendo ideal para periodos de tiempo cortos, factores que sumados a los costos de mantenimiento lo hacen poco atractivo para aplicaciones grandes.

En términos generales, la mayoría de los modelos empíricos no tienen buen rendimiento para la predicción de problemas que están sometidos a cambios constantes, ruidos en los datos y correlaciones complejas entre variables dependientes e independientes.

Los algoritmos de Machine Learning y de Deep learning tienen un especial rendimiento en estas aplicaciones dado que pueden trabajar con grandes cantidades de datos y ajustarse a relaciones complejas entre ellos.

Uno de los problemas de las aplicaciones de algoritmos de inteligencia artificial son los datos con los que los modelos matemáticos se entrenan, dado que a partir de esta información se genera su arquitectura interna, y a partir de ella pueden dar predicciones.

6.3.3 Redes neuronales recurrentes:

Para predecir la cantidad de energía solar generada hay que considerar el patrón temporal que le antecede, junto con la evolución que los datos adquiridos cada vez que se toma una medida. No es conveniente implementar redes neuronales con arquitectura fija cuando los datos tienen dependencia temporal, sobre la que se realiza una tarea de clasificación o de regresión, ya que no pueden predecir la evolución con el tiempo, sino que tienden a dar un valor ajeno a este, por ejemplo, no es lo mismo realizar una medida durante el verano, realizarla durante el invierno, aun así se presentan condiciones similares, por ejemplo, la temperatura, nubosidad, o radiación, ya que no será el mismo comportamiento, si se toma unas horas después.

En este trabajo se aplicarán series de tiempo para realizar el análisis de los datos obtenidos. Una manera de analizar la dependencia temporal de la generación energética es revisar la gráfica que resulta comparar el promedio de potencia generada por una planta según la hora, donde la mayoría se genera durante las 10 y 2 de la tarde.

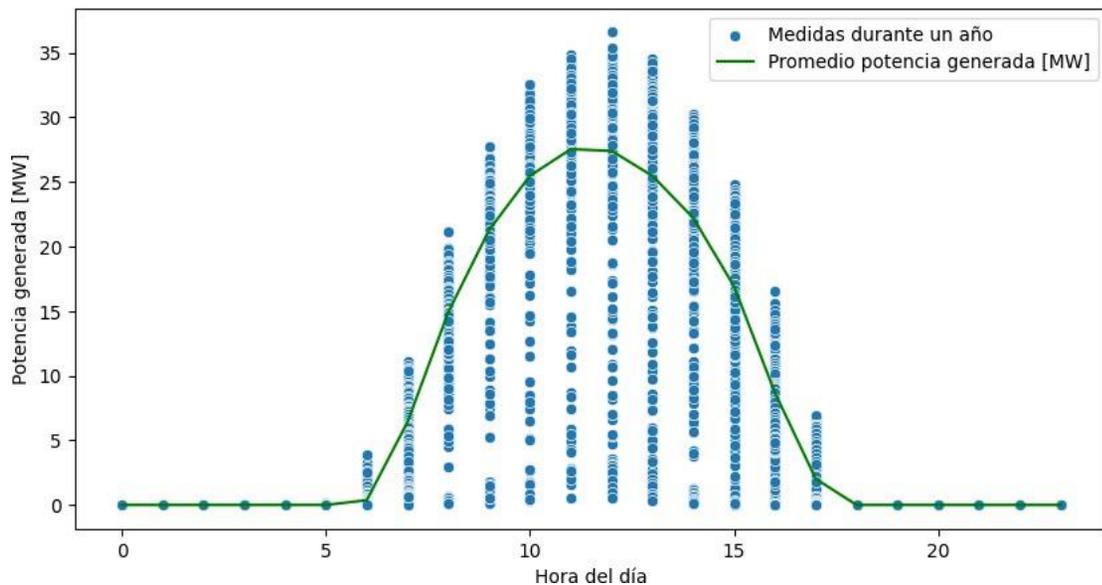


Ilustración 11. Comportamiento promedio de la potencia generada en un día.

7. Planteamiento del problema

A partir del comportamiento de la información recolectada se puede observar que la fluctuación promedio por durante un año presenta grandes variaciones, siendo difícil establecer patrones anuales, o incluso mensuales. Se presentan grandes fluctuaciones incluso en periodos semanales o diarios, generándose los saltos de radiación que se pueden observar en la ilustración 12.

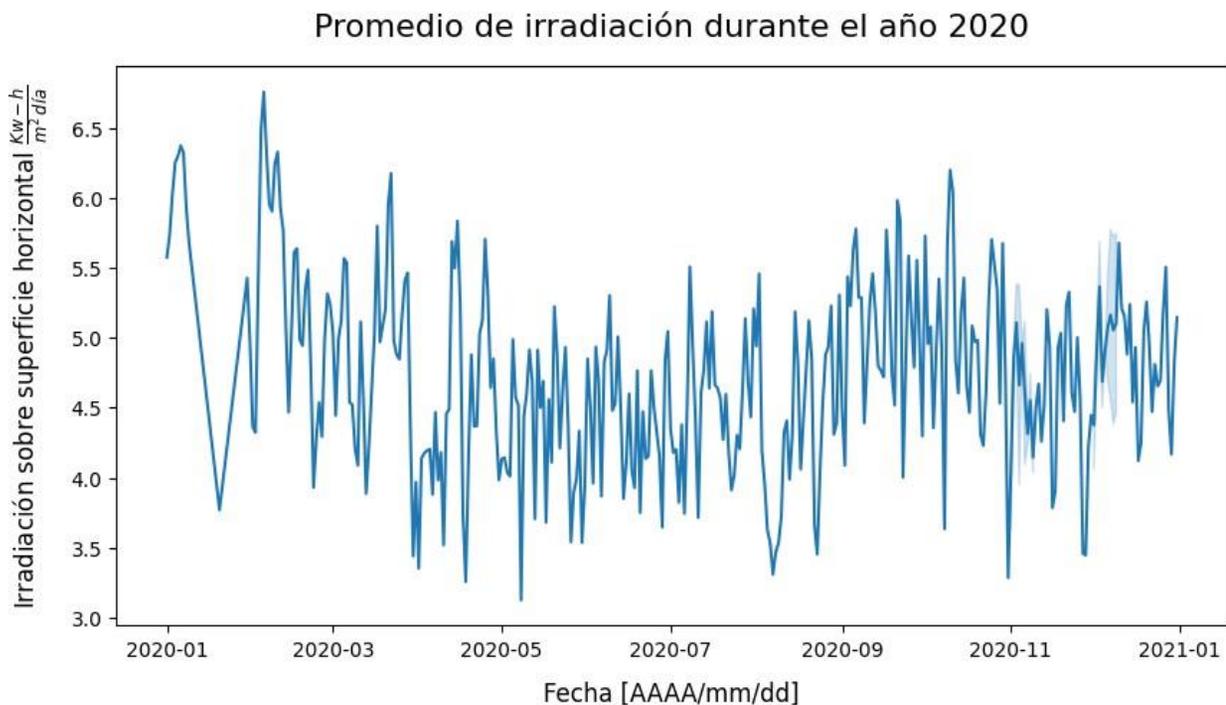


Ilustración 12. Comportamiento promedio de la radiación durante un año.

La ilustración 13 muestra una comparación entre la radiación promedio tomando los datos mensuales y diarios. A partir de esta ilustración se puede determinar que el máximo de radiación mensual a lo largo de todo el 2020 es de $5.4 \left[\frac{Kw-h}{m^2*Dia} \right]$, mientras que al tomar un periodo de tiempo diario, y obtener los mismos datos, se tiene un máximo de $6.7 \left[\frac{Kw-h}{m^2*Dia} \right]$, por tanto, en el caso de que se realice un análisis aproximado de la máxima potencia que se podría generar, hay un error

aproximado del 20%, lo que podría conllevar a malas decisiones a la hora de escoger los equipos de energía fotovoltaica, porque la estimación de las capacidades de los equipos generadores dependerían en gran parte de los datos que fueron tomados por el equipo de ingenieros.

De igual manera, se puede observar que cuando el periodo es más largo, la dispersión de los datos se reduce, dando como resultado una desviación estándar más baja comparada con el periodo diario.

Una característica que vale la pena resaltar, es que la mediana de ambos análisis presenta pocas diferencias, además, todos los datos cuando se realizan los promedios mensuales tienden a agruparse entre el percentil 25 y 75 de los datos analizados diariamente, reduciendo la varianza de los datos diarios que son menores al percentil 25 y mayores al percentil 75, agrupándolos hacia la mediana. Por tanto, se recomienda tomar los datos con el periodo de tiempo más corto posible, de esta manera los patrones que serán predichos estarán mucho más cercanos a las medidas reales.

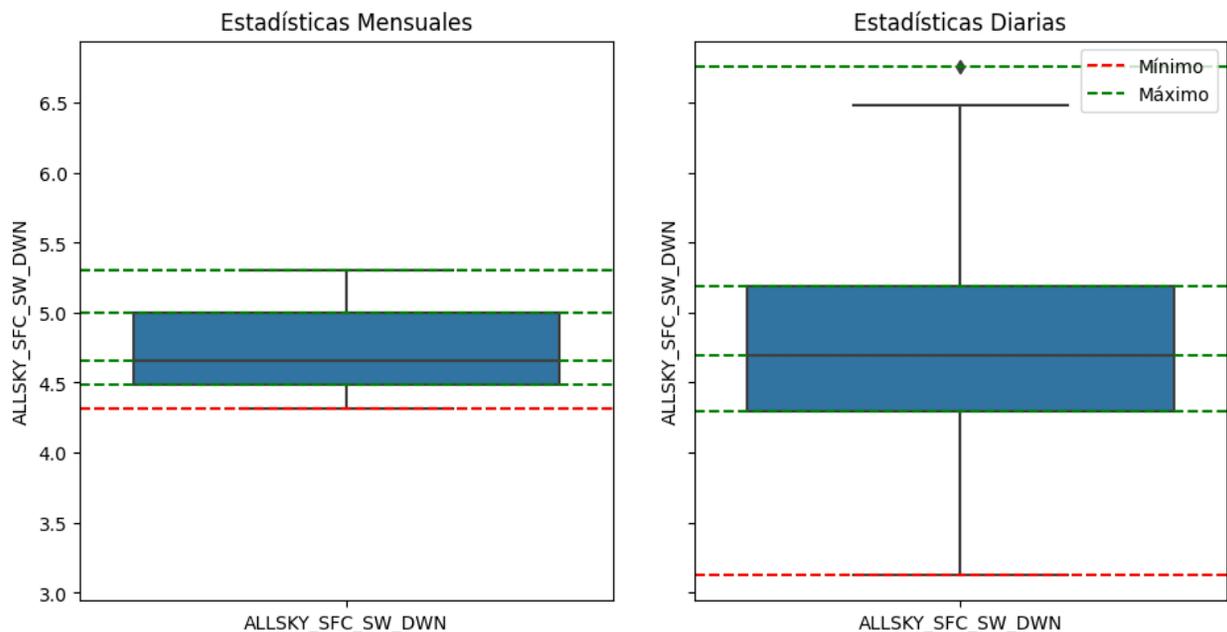


Ilustración 13. Comparación de los datos estadísticos con datos diarios y mensuales.

Dada la prevalencia del orden temporal en el cual se encuentran distribuidos los datos, se deben tener en cuenta otros tipos de análisis para la generación del modelo, uno de ellos es respetar la continuidad de los datos durante la división de estos, que será explicada brevemente. Generalmente, en problemas no relacionados con series de tiempo la selección de los datos se hace con el método **Standard k-fold**, en este método los datos que se guardan para validar, en la ilustración 14 de color naranja en el recuadro izquierdo, son extraídos aleatoriamente, dejando los datos en azul para validar el modelo, y con cada iteración, este conjunto de validación va cambiando aleatoriamente a lo largo del conjunto de datos. Estos métodos conocidos como validación cruzada se utilizan para aumentar la aleatoriedad del modelo y reducir la dependencia que va generando el modelo durante el proceso de entrenamiento con el Dataset.

En el caso de un modelo de series de tiempo, los datos no pueden ser sacados aleatoriamente, dado que se afecta la parte temporal de este, este método se conoce como **time series cross validation**, que toma pequeñas porciones de datos para entrenar y para validar, esta porción va aumentando a lo largo de cada iteración, conservando la última porción del Dataset de manera ordenada, que pertenezca a los últimos datos temporales del conjunto de entrenamiento y validación, estos datos son los que se encuentran de color naranja en la parte derecha de la ilustración mostrada a continuación.

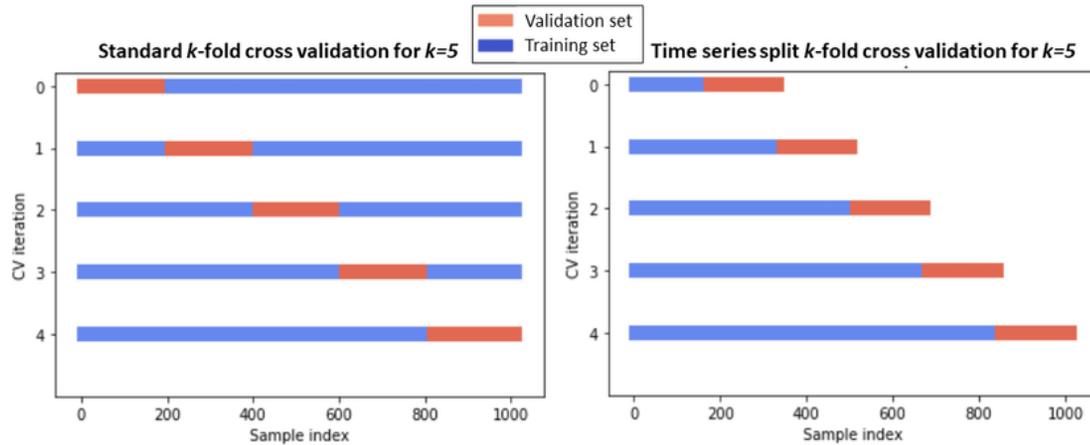


Ilustración 14. Imagen tomada de Predicting the Price of Crude Oil and its Fluctuations Using Computational Econometrics: Deep Learning, LSTM, and Convolutional Neural Networks - Scientific Figure on ResearchGate. Available from: https://www.researchgate.net/figure/Classical-k-fold-cross-validation-vs-time-series-split-cross-validation_fig1_355889701 [accessed 25 Nov, 2023].

Otro factor para tener en consideración para mantener la relación temporal del Dataset, es la arquitectura del modelo de Deep Learning para manejar la dimensión del tiempo de los datos, en otras palabras, es poder generar un modelo que, basado en los datos anteriores pueda realizar una predicción del dato siguiente a las fechas tomadas. Por ejemplo, basados en los registros del promedio de energía generada durante los 12 meses anteriores, se necesita conocer el promedio que va a ser generado durante los tres meses siguientes.

7.1 Funcionamiento de la red de captación de energía solar.

El sistema de recolección de energía solar está compuesto por los siguientes componentes:

7.1.1 Paneles Solares.

La radiación generada por el sol es captada por los paneles solares, que se encargan de convertirla a energía eléctrica mediante el efecto fotoeléctrico, generado cuando un semiconductor es expuesto a la luz, y un fotón golpea a un electrón, desplazándolo y dejando un espacio libre en el átomo excitado. Este espacio libre rápidamente se llenará con otro electrón, haciendo que la energía liberada por el fotón sea disipada en forma de calor. Cuando este efecto se presenta en masa, lo que hace es obligar a los electrones y agujeros a moverse hacia el lado opuesto del material, produciendo una diferencia de potencial, y generando tensión entre las dos caras opuestas del panel.

El material con el que está fabricado el panel solar es muy importante en cuanto a términos de eficiencia, generalmente se recomienda trabajar con paneles monocristalinos con potencias cercanas a los 500 [wp], intentando maximizar la cantidad de celdas, lo que generará una reducción en la cantidad de paneles necesarios, sin reducir la energía generada.

Este tipo de paneles solar se pueden conseguir fácilmente en el mercado. En este trabajo se harán los cálculos basados en los paneles Solares de la marca Jinko, cuyas características se encuentran en las siguientes imágenes:

Tiger Neo N-type 72HL4-(V) 565-585 Watt MONO-FACIAL MODULE

N-Type

Positive power tolerance of 0~+3%

IEC61215(2016), IEC61730(2016)

ISO9001:2015: Quality Management System

ISO14001:2015: Environment Management System

ISO45001:2018

Occupational health and safety management systems



Engineering Drawings

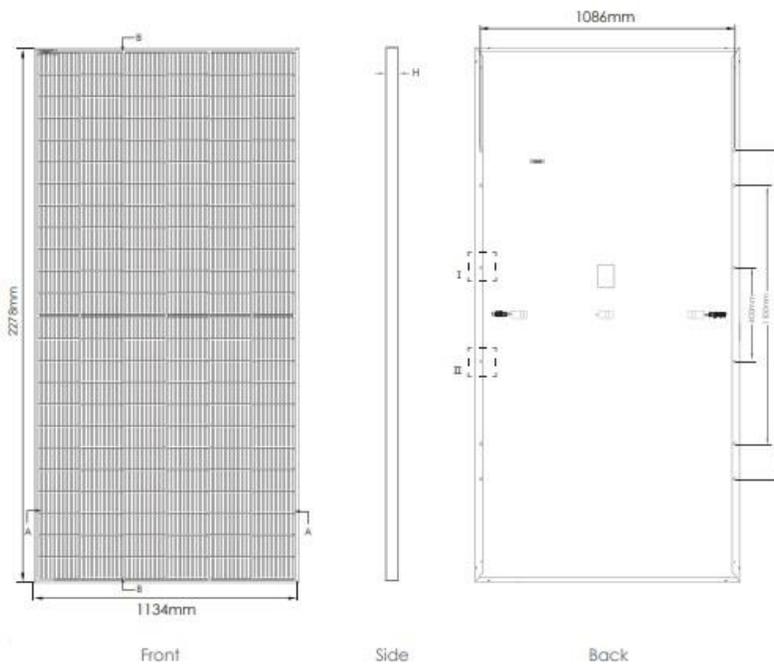


Ilustración 15 Características y dimensiones de los paneles solares.

Cuando ya se conoce la hora solar pico, junto con la potencia del panel solar, se podrá calcular la energía teórica generada por este mediante la siguiente ecuación extraída de (Morcillo-Herrera, C., Hernández, 2014):

$$E_{generada} = P_{panel} \times HSP_{corr} [kWh] \text{ Ec. (6).}$$

Y para calcular el número de paneles solares requeridos, se hace uso de la siguiente ecuación:

$$N_{paneles} = \frac{E_{req}}{E_{generada}} \text{ Ec. (7).}$$

Con el número de paneles calculados en la ecuación 7, se procede a calcular el área y la potencia que suministrarán:

$$A = N_{paneles} \times Length \times Width \text{ Ec. (8).}$$

$$P_{total} = P_{panel} \times N_{paneles} \text{ Ec. (9).}$$

Usualmente, dependiendo del tipo de aplicación que se necesite, se realiza la conexión entre los paneles solares, teniendo en cuenta que, al realizar una conexión en serie, se acumulará el voltaje generando corriente constante, mientras que en paralelo el voltaje es el que se mantiene constante a lo largo de la instalación. Cuando la conexión se hace en serie, el voltaje acumulado llega a unos límites muy alto, por tanto, no es recomendable, mientras que la conexión en paralelo los tiende a estabilizar evitando la generación de picos en la tensión, por lo cual es una conexión que es ampliamente utilizada en las aplicaciones fotovoltaicas. Para este cálculo se debe tener en cuenta la Hora Solar Pico.

Cuando la radiación alcanza su punto máximo en el día se conoce como la Hora solar pico, en este punto es en donde el Sol se encuentra en la posición más alta, generando la energía máxima que puede captar un panel solar. En este punto es en donde se dispone la mayor cantidad de energía producida por una planta, este comportamiento se puede observar en la ilustración 4 que fue presentada anteriormente en donde se comparaba la potencia producida por una planta, junto con las horas del día.

No se consideró importante este parámetro para ser ingresado dentro del modelo dado que varía según el sitio de instalación del Panel solar, siendo afectado por configuraciones específicas como por ejemplo sombras de árboles o de construcciones, y también por lo ángulos de inclinación del panel solar.

La Hora solar pico corregida se encuentra descrita por la siguiente ecuación, tomada de (Zhang, Huili & Baeyens, 2013):

$$HSP_{corr} = HSP \times k \times k_1 \times k_2 \left[\frac{kWh}{m^2} \right] \text{ Ec. (10).}$$

En donde:

- HSP_{corr} : Irradiación u Hora pico solar corregida
- k : Factor de corrección para la inclinación del panel.
- k_1 : Factor de corrección por factores atmosféricos.
- k_2 : Factor de corrección por orientación.

La conexión en paralelo de los paneles se crea al conectar todos los polos positivos en común, y repitiendo el mismo procedimiento con los polos negativos de todos los paneles del sistema, esta conexión se visualiza en la siguiente ilustración:

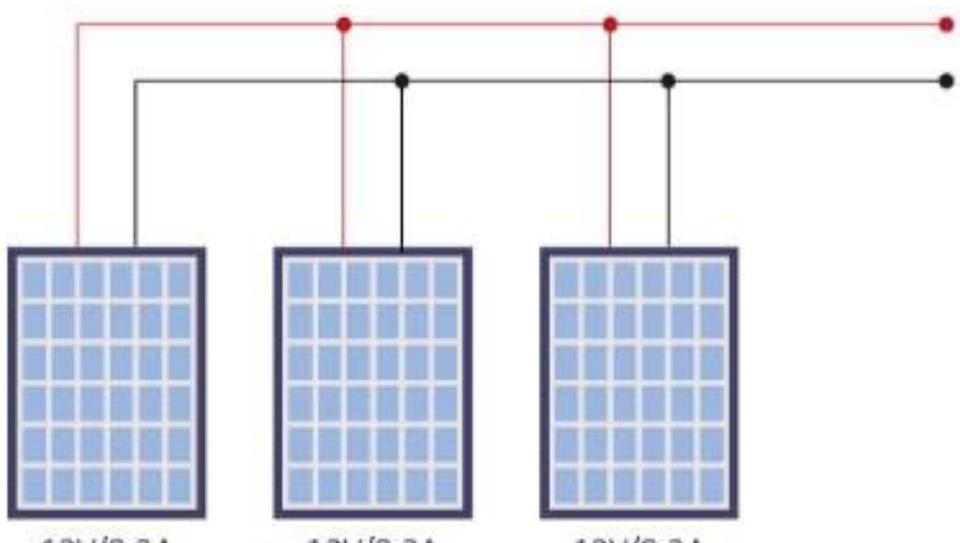


Ilustración 16. Ilustración gráfica de un montaje de paneles solares con conexión en paralelo.

7.1.2 Regulador:

La generación de energía solar presenta grandes variaciones a lo largo del día, por ejemplo, para el año 2020, año que se tomó como referente para realizar las comparaciones, se presentan grandes diferencias, en la siguiente tabla se muestran los valores máximos, mínimos y el promedio de la radiación.

Tabla 3 Variación en la magnitud de la radiación a lo largo del día.

ALLSKY_SFC_SW_DOWN [Kw-h/(m ² *dia)]	
mean	4.743192
min	0.73
max	7.68

Con los valores extremos tan alejados entre sí, suelen presentarse varias complicaciones en las instalaciones solares, una necesidad de estas instalaciones es controlar la carga de los acumuladores de energía, o baterías, que serán explicados más adelante.

Una de las funciones de regulador, es proteger la sobrecarga de las baterías durante las horas pico de generación solar, las cuales son generalmente al medio día, así mismo, en horas nocturnas, en donde la radiación solar llega a su mínimo, debe evitar que las baterías sufran descargas excesivas, lo que acorta la vida útil y reducen la capacidad de almacenamiento de energía.

Los reguladores también cumplen un papel similar al de un fusible, dado que deben proteger el sistema contra sobrecargas de corriente y corto circuitos.

Dependiendo de la aplicación que se necesite son escogidos los reguladores, en este caso se toma como ejemplo la serie MPPT que son ampliamente comerciales, y presentan características muy importantes para aplicaciones con Inteligencia artificial, tales como monitoreo de datos y conexión al celular para realizar un rastreo de la energía que está siendo suministrada por el sistema. Las características de estos reguladores se encuentran en las siguientes imágenes tomadas del catálogo.

Controlador de carga BlueSolar	MPPT 100/30	MPPT 100/50
Tensión de la batería	Selección automática: 12/24V	
Corriente de carga nominal	30A	50A
Potencia FV nominal, 12V 1a,b)	440W	700W
Potencia FV nominal, 24V 1a,b)	880W	1400W
Tensión máxima del circuito abierto FV	100V	100V
Max. corriente de cortocircuito FV 2)	35A	60A
Eficacia máxima	98%	98%
Autoconsumo	12V: 30 mA 24V: 20 mA	
Tensión de carga de "absorción"	Valores predeterminados: 14,4 V / 28,8 V (ajustable)	
Tensión de carga de "flotación"	Valores predeterminados: 13,8 V / 27,6 V (ajustable)	
Algoritmo de carga	variable multietapas	
Compensación de temperatura	-16 mV / °C, -32 mV / °C resp.	
Temperatura de trabajo	-30 a +60°C (potencia nominal completa hasta los 40°C)	
Humedad	95 %, sin condensación	
Puerto de comunicación de datos	VE.Direct Consulte el libro blanco sobre comunicación de datos en nuestro sitio web	
CARCASA		
Color	Azul (RAL 5012)	
Terminales de conexión	16mm ² / AWG6	
Tipo de protección	IP43 (componentes electrónicos), IP22 (área de conexión)	
Peso	1,3kg	1,3kg
Dimensiones (al x an x p)	130 x 186 x 70mm	130 x 186 x 70mm
ESTANDARES		
Seguridad	EN/IEC 62109-1, UL 1741, CSA C22.2	
1a) Si hubiese más potencia FV conectada, el controlador limitará la potencia de entrada. 1b) La tensión FV debe exceder en 5V la Vbat (tensión de la batería) para que arranque el controlador. Una vez arrancado, la tensión FV mínima será de Vbat + 1V. 2) Un generador fotovoltaico con una corriente de cortocircuito más alta puede dañar el controlador		

Controladores de carga BlueSolar MPPT 100/30 & 100/50

www.victronenergy.com



Controlador de carga solar MPPT 100/50

Seguimiento ultrarrápido del punto de máxima potencia (MPPT, por sus siglas en Inglés)
Especialmente con cielos nubosos, cuando la intensidad de la luz cambia continuamente, un controlador MPPT ultrarrápido mejorará la recarga de energía hasta en un 30%, en comparación con los controladores de carga PWM, y hasta en un 10% en comparación con controladores MPPT más lentos.

Detección Avanzada del Punto de Máxima Potencia en caso de nubosidad parcial
En casos de nubosidad parcial, pueden darse dos o más puntos de máxima potencia (MPP) en la curva de tensión de carga. Los MPPT convencionales tienden a seleccionar un MPP local, que pudiera no ser el MPP óptimo. El innovador algoritmo de BlueSolar maximizará siempre la recarga de energía seleccionando el MPP óptimo.

Excepcional eficiencia de conversión
Sin ventilador. La eficiencia máxima excede el 98%. Corriente de salida completa hasta los 40°C (104°F).

Algoritmo de carga flexible
Algoritmo de carga totalmente programable (consulte la sección Asistencia y Descargas > Software en nuestra página web), y ocho algoritmos preprogramados, seleccionables mediante interruptor giratorio (ver manual para más información).

Amplia protección electrónica
Protección de sobretensión y reducción de potencia en caso de alta temperatura.
Protección de cortocircuito y polaridad inversa en los paneles FV.
Protección de corriente inversa FV.

Sensor de temperatura interna
Compensa la tensión de carga de absorción y flotación, en función de la temperatura.

Opciones de datos en pantalla en tiempo real

- ColorControl GX u otros dispositivos GX consulte los documentos Venua en nuestro sitio web.
- Un smartphone u otro dispositivo con Bluetooth: se necesita la mochila VE.Direct Bluetooth Smart.



Ilustración 17 Características de los reguladores de energía.

7.1.3 Baterías:

Las baterías son las encargadas del almacenamiento de energía para poder tener un suministro constante sin importar la hora del día, ya sea de noche, cuando la radiación solar es muy baja, o de día en los picos máximos de generación. También cumplen un papel importante durante temporadas invernales cuando las condiciones climáticas no son las mejores para poder generar un suministro constante de energía.

La elección de las baterías se hace según el consumo diario que se necesite, junto con la capacidad de descarga de ellas. Para aplicaciones residenciales, generalmente se utilizan baterías de 12, 24, o 48V. Adicionalmente, según el tipo de consumo, se escoge el tipo de baterías, en caso de que se desee un tiempo de vida prolongado, se recomiendan las baterías estacionarias, porque tienen buen precio, son muy comerciales y la vida útil es muy larga, alcanzando periodos superiores a los 20 años.

7.1.4 Inversor:

La energía de salida del montaje de paneles solares es corriente directa (CD), pero en los hogares se utiliza corriente alterna para el funcionamiento de los electrodomésticos, o en el caso de aplicaciones empresariales, para el funcionamiento de las máquinas, por esta razón es necesario realizar la conversión de CD a CA.

La función de los inversores es realizar este cambio, de manera que la energía suministrada pueda ser utilizada en las aplicaciones necesarias con los dispositivos y electrodomésticos. Los inversores ajustan la corriente y el voltaje de manera adecuada para poder obtener el máximo rendimiento de los paneles solares. Los inversores permiten la capacidad de monitorear el rendimiento de la red eléctrica, y también en los sistemas conectados a la red permiten el suministro de electricidad según sea demandado por los componentes.

La selección del inversor se toma basada en la potencia y voltaje con que se va a trabajar. Se recomienda tomar factores de seguridad generalmente del 20% para evitar sobredimensionamientos, y asegurar que siempre se va a trabajar con potencias menores a las máximas permitidas por el equipo.

7.2 Entrenamiento de la red Neuronal:

Durante el entrenamiento del modelo predictivos se siguieron los pasos mencionados en la ilustración 8 del flujo de trabajo para la creación de modelos de Inteligencia artificial.

Inicialmente, luego de la recolección de los Datasets, se realiza una mezcla de estos para obtener uno solo que pueda ser integrado al modelo predictivo, este proceso se conoce como “merge”, y consiste en combinar varios conjuntos de datos en uno solo para poder centralizar la información que va a ser utilizada en el proceso. Los Datasets utilizados se encontraban en formato **.csv** fueron pasados a formato **DataFrame** de la librería Pandas de Python, cuyo Dataset resultante fue dividido en los conjuntos de entrenamiento, validación y de testeo. En la ilustración 18 se muestra de manera gráfica el procedimiento que se realizó para crear un solo conjunto de datos:



Ilustración 18. Esquema ilustrativo del proceso de merge realizado en los Datasets.

7.2.1 Elección de las funciones de activación:

Todas las neuronas de la red dan como salida un valor numérico, cuando se habla de funciones de activación, se están considerando funciones que son agregadas a los datos de salida de cada nodo de la red. El objetivo de las funciones de activación es ayudar a que la red se ajuste a patrones complejos en los datos, estas funciones pueden ser comparadas con el modelo cerebral porque determinan cuales son los datos que van a ser enviados a las próximas neuronas, dependiendo del tipo de salida elegido, se pueden elegir con el modelo On/Off, que envían unos o ceros, determinando si activan o no los nodos que van después de ellos.

En la siguiente ilustración se muestra un esquema del funcionamiento de un nodo de la red neuronal. Como parámetros de entrada a este nodo, llegan los datos del Dataset, denotados como $x_0, x_1, x_2, \dots, x_n$. Estos parámetros van a ser multiplicados por unos valores numéricos $w_0, w_1, w_2, \dots, w_n$ cuyos valores se van a ir ajustando según la red neuronal se vaya entrenando.

Una vez se han realizado las operaciones de los parámetros de entrada x_n con los pesos de la red neuronal w_n , se procede a realizar una suma pesada de estos valores, que en la ilustración se encuentran denotadas en la ecuación 11, las ecuaciones siguientes fueron tomadas de (Popescu, M. C., Balas, 2009):

$$\sum x_i \times w_i + b \text{ Ec. (11).}$$

El resultado de esta suma pesada es el valor de salida de cada neurona de la red, ahora bien, dependiendo del tipo de aplicación de la red se elige que tratamiento darle a este resultado. La función que se va a aplicar se conoce como función de activación, denotada en la ilustración 19 como:

$$f(\sum x_i \times w_i + b) \text{ Ec. (12).}$$

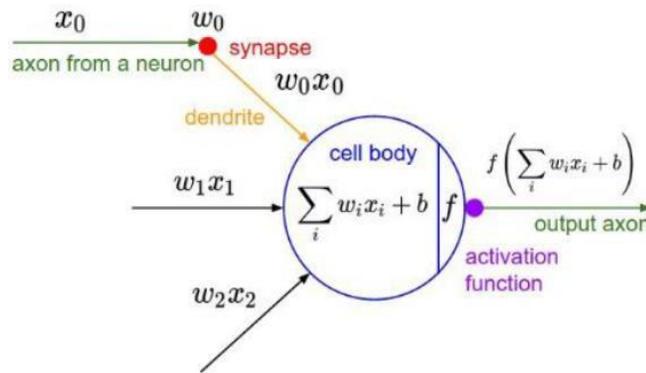


Ilustración 19 Esquema del funcionamiento de un perceptrón.

La función de activación de la red está en la capacidad de modificar los datos según se desee, ya sea dejar una salida binaria, por ejemplos unos o ceros, o salidas acotadas entre dos valores, por ejemplo, entre el 0 y el 1, tal como se puede observar en la siguiente gráfica en la parte correspondiente a la activación sigmoide, cuya ecuación está dada por:

$$\sigma = \frac{1}{1 + e^x} \text{ Ec. (13).}$$

7.2.2 Funciones de activación

Dado que, en el modelo, los valores de la variable a predecir presentan grandes fluctuaciones, y los límites no están bien definidos, no se recomienda utilizar ninguna función que modifique de tal manera los datos, sino que se recomienda utilizar una función lineal como función de activación, de esta manera, la red tendrá una mayor capacidad de ajuste a los patrones del conjunto de datos, la gráfica de esta función se encuentra también en la ilustración siguiente.

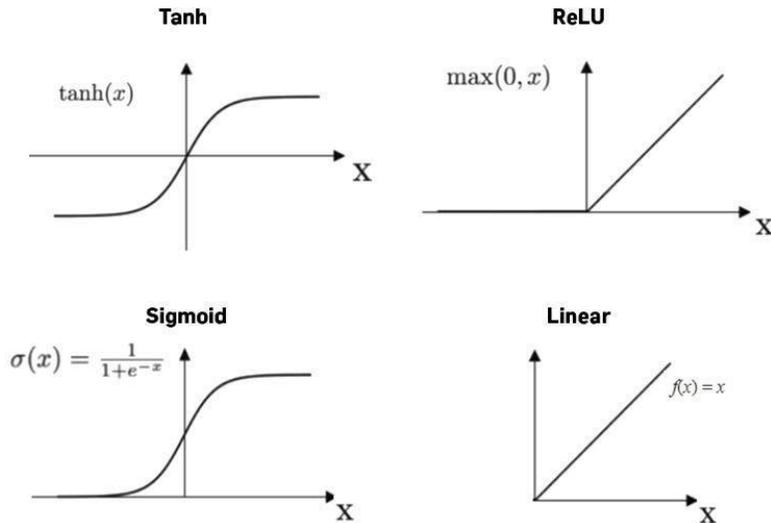


Ilustración 20 Funciones de activación de la red neuronal.

7.2.3 Inicialización de los pesos y valores del Bias:

En la ilustración 20 se observan valores denotados como w_i y b_i , estos valores son conocidos respectivamente como pesos y bias. Como punto de partida se va a tomar dicha ilustración para explicar el procedimiento.

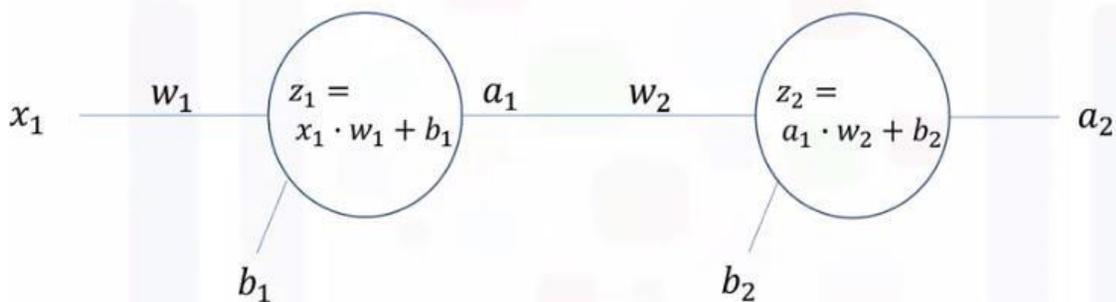


Ilustración 21 Flujo matemático de operaciones entre dos neuronas.

Como primer paso, se generan valores aleatorios tanto de los pesos, como de los Bias, y a partir de ahí, se sigue el método de Forward-Propagation, que es realizar la operación de izquierda a derecha, es decir, primero se multiplican los valores de entrada x_i con los pesos w_i y posteriormente se suma este valor al Bias, es decir, para la ilustración de ejemplo se hace la siguiente operación:

$$\sum x_1 \times w_1 + b_1 \quad \text{Ec. (14).}$$

Posteriormente, el valor de esta suma pesada se lleva a la función de activación, que fue discutida anteriormente, el resultado de esta función se denotará como a_1

$$f(\sum x_1 \times w_1 + b_1) = a_1 \quad \text{Ec. (15).}$$

Ahora, a_1 será ingresado como parámetro de entrada a la segunda neurona, en donde se realizará la suma pesada, junto con la función de activación, y dará como resultado el valor de salida, o valor predicho denotado por a_2 .

7.2.4 Cálculo del error entre el valor predicho y el valor real.

Una vez conocido el valor de a_2 , se calcula el error que presenta con el valor real de la variable a predecir. En este trabajo se utilizó la ecuación del error cuadrático medio durante el entrenamiento de la red neuronal. Este error se calcula con la siguiente ecuación, tomada de (Gerón. A, 2019), en donde se realiza una resta entre el valor real y predicho, se eleva al cuadrado y después se divide en dos, entre más bajo el valor resultante, mejor será la predicción:

$$E = \frac{(y - a_2)^2}{2} \quad \text{Ec. (16).}$$

Ahora, para optimizar el valor del peso w_1, w_2 se utilizará una derivada para ir disminuyendo iterativamente el valor y llegar al mínimo de la función de pérdida, lo cual indica que con esto se



espera reducir el error, acercando el valor predicho al valor real, esto se hace mediante la siguiente ecuación, extraída de (LeCun, Y., Touresky, D., 1988):

$$w_2 \rightarrow w_2 - \mu * \frac{\sigma E}{\sigma w_2} \quad Ec. (17).$$

Al derivar parcialmente la función de error, se tiene como resultado la siguiente ecuación:

$$\frac{\sigma E}{\sigma w_2} = \frac{\sigma E}{\sigma a_2} \times \frac{\sigma a_2}{\sigma w_2} = -(y - a_2) \times (a_2 \times (1 - a_2)) \times a_1 \quad Ec. (18).$$

Y finalmente, el nuevo valor de w_2 se define con la ecuación siguiente:

$$w_2 \rightarrow w_2 - \mu \times (-(y - a_2)) \times (a_2 \times (1 - a_2)) \times a_1 \quad Ec. (19).$$

μ es un parámetro elegido por el programador, que determina la magnitud del cambio en la magnitud de los pesos, sin embargo, se va a dejar un valor por defecto de 0.001.

8. Resultados.

Para entrenar la red neuronal se tomaron varias arquitecturas de redes neuronales recurrentes, eligiendo la red que mejor desempeño tuvo. Dado que los resultados de salida del modelo predictivo son numéricos, se tomó la métrica llamada MAPE (mean average precision), conocido en español como error absoluto medio. Esta métrica se encarga de expresar la diferencia entre el valor predicho y real por medio de un porcentaje, lo cual ayuda a comparar modelos entre sí con mayor facilidad gracias a porcentaje resultante de la comparación. La ecuación de esta métrica está descrita por la ecuación 20, consultada en (Gerón. A, 2019):

$$MAPE = \frac{1}{n} \sum \left| \frac{y_i - \hat{y}}{y_i} \right| \text{ Ec. (20).}$$

En donde:

- n : Es el número total de observaciones.
- \hat{y} : Valor real.
- y_i : Valor predicho por el modelo.

A partir de los resultados de esta métrica se eligió el mejor modelo.

8.1 Modelo LSTM:

Las redes neuronales LSTM son un tipo de red neuronal recurrente con la capacidad de aprender la dependencia de orden durante la predicción de los datos. Son ampliamente utilizadas en el ámbito de traducciones, reconocimiento de voz y procesamiento de videos. En este trabajo se utilizaron este tipo de redes suministradas por TensorFlow, una librería muy reconocida en el área de IA por su gran completitud en cuanto a modelos, y facilidad para poder entrenar modelos de inteligencia artificial. El rendimiento de este modelo durante el proceso de entrenamiento y validación se encuentra en la ilustración 22, en donde se puede observar la diferencia que hay entre el MAP de los datos de entrenamiento y los de validación. Siendo más bajo el error entre los datos de

entrenamiento, lo cual indica que el modelo se desempeña bien prediciendo los datos con los cuales ha sido entrenado, es decir, con los datos que ya conoce, generando una mayor dificultad realizar la predicción de los datos que aún no han ingresado a la red. Esto nos indica, que esta arquitectura no es la ideal para llevar el modelo a un ambiente de producción, porque no tiene la capacidad de predecir datos que no han ingresado al modelo, después de varios intentos, el mínimo error absoluto conseguido con esta arquitectura fue de 17% en los datos de entrenamiento, mientras que en los datos de validación fue un porcentaje cercano al 19%, lo cual quiere decir que, si bien no alcanza a tener un MAPE bajo, el modelo tiene un buen ajuste a los datos de validación, lo que indica que el entrenamiento está siendo ejecutado con los parámetros adecuados.

Desempeño del modelo LSTM durante entrenamiento con periodo diario

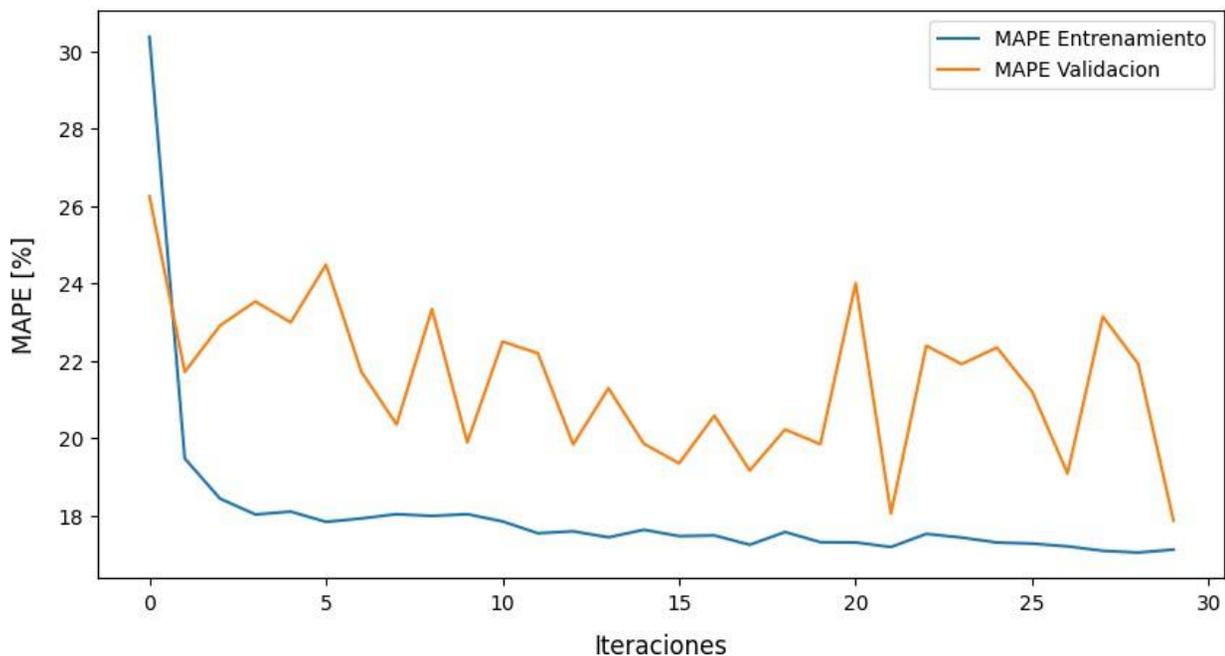


Ilustración 22 Rendimiento del modelo LSTM durante el entrenamiento y validación, con periodo de tiempo de un día.

A pesar de las grandes fluctuaciones que se presentan en las métricas durante el entrenamiento, el modelo tiene un ajuste muy bueno a los datos, alcanzando métricas cercanas a los resultados esperados, en donde los modelos LSTM presentan errores cercanos al 20% con la métrica de MAE (Chen, H., & Chang, X, 2021).

Una vez el modelo estuvo entrenado, se realizó una predicción con los datos de radiación solar a lo largo de un año, cuya gráfica se encuentra en la ilustración 23. Se puede observar que, a pesar de que se presentan algunas diferencias entre las curvas, la predicción realizada por la red neuronal tiende a seguir las tendencias en la radiación, por lo tanto, es una buena herramienta para poder realizar estimaciones cuando se va a realizar una instalación de paneles solares.

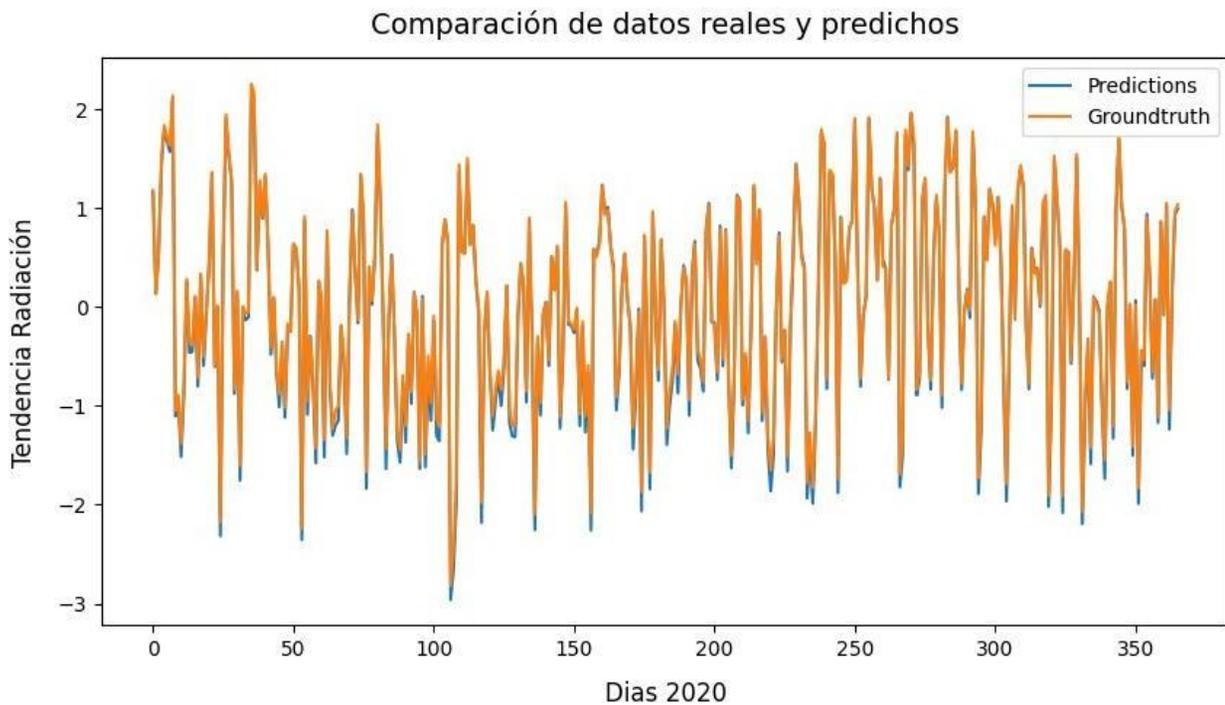


Ilustración 23 Comparación realizada entre los datos predichos y reales durante un año.

Estas predicciones realizadas pueden mejorarse al incrementar la cantidad de variables que son ingresadas al modelo. A pesar de que se utilizaron varios Datasets de distintas fuentes en distintas épocas del entrenamiento, sigue presentándose poca riqueza en cuanto a datos para poder realizar las predicciones. Fue muy difícil conseguir datos que fueran tomados con intervalos de tiempo menores a una hora, y que cumplieran con datos de buena calidad, o también con grandes cantidades de datos, los pocos Datasets que cumplían con intervalos pequeños de medidas, solo contenían información de unas pocas semanas o meses, o tenían pocas variables que podían ser ingresadas al Dataset.

Los Datasets que contenían mayor cantidad de datos, y que además tenían largos periodos de tiempo, eran los extraídos por la Nasa, sin embargo, contenían información importante para intervalos de un día, mientras que, para datos con frecuencias de una hora, se tenía restricciones en cuanto a los datos que se podían extraer. Se probó también la extracción de los datos haciendo uso de la API proporcionada por la NASA, como alternativa a la interfaz gráfica que tenía restricciones para descargar los datos, sin embargo, el resultado fue el mismo, dado que está desactualizada y presenta varios errores durante la extracción de los datos, complicando el análisis posterior. En la ilustración 24 se da a conocer un fragmento de código utilizado para obtener los datos mediante la API.

```
locations = [(6.2598, -75.5772)]

output = r""
base_url = r"https://power.larc.nasa.gov/api/temporal/hourly/point?parameters='QV2M','RH2M','PRECTOTCORR','CLRSKY_SFC_S

for latitude, longitude in locations:
    api_request_url = base_url.format(longitude=longitude, latitude=latitude)

    response = requests.get(url=api_request_url, verify=True, timeout=30.00)

    content = json.loads(response.content.decode('utf-8'))
    filename = response.headers['content-disposition'].split('filename=')[1]

    filepath = os.path.join(output, filename)
    with open(filepath, 'w') as file_object:
        json.dump(content, file_object)
```

Ilustración 24 Obtención de datos para la ciudad de Medellín con frecuencia horaria.

9. Conclusiones

- La predicción de la energía solar generada conlleva la consideración de una gran cantidad de variables, que no tienen una incidencia clara con la producción de energía solar, por tanto, al realizar un modelo matemático sin ayuda computacional se pueden crear ecuaciones demasiado complejas para poder entregar soluciones cercanas a las medidas reales, siendo necesaria la implementación de otras herramientas que acarreen costos innecesarios.
- A pesar de que las fuentes de combustible fósil son las más utilizadas en la actualidad, representan un gran riesgo para la vida humana según la información recolectada, siendo las muertes presentadas debido a complicaciones respiratorias, accidentes durante la recolección de la materia prima y producción energética, mientras que las fuentes de energía renovables son muy seguras, presentando un histórico de muertes despreciable en comparación con los otros medios de producción.
- A partir de los resultados obtenidos en la fase de validación, se determina la eficacia del modelo, dado que se ajusta de una buena manera a los datos, y al realizar la predicción y compararla con el histórico de un año, se tiene una predicción bastante acertada del comportamiento de la radiación durante todo el año.
- En caso de que se requiera un modelo más acertado, es necesario realizar la búsqueda de otras herramientas de obtención de los datos, dado que a pesar de que había varios Datasets disponibles de manera gratuita en plataformas como Kaggle o compartidos por la Nasa, tienen varias limitaciones en torno a las variables que miden, y también la poca cantidad de datos que contienen, al igual que la frecuencia de lectura de los datos.

10. Referencias

Hannah Ritchie and Pablo Rosado (2020) - “Electricity Mix” Published online at OurWorldInData.org. Retrieved from: '<https://ourworldindata.org/electricity-mix>' [Online Resource]

Hannah Ritchie and Pablo Rosado (2020) - “Energy Mix” Published online at OurWorldInData.org. Retrieved from: '<https://ourworldindata.org/energy-mix>' [Online Resource]

Hannah Ritchie (2020) - “What are the safest and cleanest sources of energy?” Published online at OurWorldInData.org. Retrieved from: '<https://ourworldindata.org/safest-sources-of-energy>' [Online Resource]

Energy Transitions: Global and National Perspectives, 2nd edition, Appendix A, Vaclav Smil (2017).

Energy Institute - Statistical Review of World Energy (2023). Retrieved from <https://www.energyinst.org/statistical-review/>

Ember – European Electricity Review (2022). Retrieved on December 12, 2023, from [https://ember-climate.org/insights/research/european-electricity-review-2022/..](https://ember-climate.org/insights/research/european-electricity-review-2022/)

Fausett, L. V. (1994). Fundamentals of neural networks: Architectures, algorithms, and applications. Prentice Hall.

Chen, H., & Chang, X. (2021). Photovoltaic power prediction of LSTM model based on Pearson feature selection. *Energy Reports*, 7(Supplement 7), 1047-1054. <https://doi.org/10.1016/j.egy.2021.11.019>.

Popescu, M. C., Balas, V. E., Perescu-Popescu, L., & Mastorakis, N. (2009). Multilayer perceptron and neural networks. *WSEAS Transactions on Circuits and Systems*, 8(7), 579-588.

Sedai, A.; Dhakal, R.; Gautam, S.; Dhamala, A.; Bilbao, A.; Wang, Q.; Wigington, A.; Pol, S. Performance Analysis of Statistical, Machine Learning and Deep Learning Models in Long-Term Forecasting of Solar Power Production. *Forecasting* **2023**, 5, 256-284. <https://doi.org/10.3390/forecast5010014>

Zhang, Huili & Baeyens, J. & Degrève, Jan & Cáceres, Gustavo. (2013). Concentrated solar power plants: Review and design methodology. *Renewable and Sustainable Energy Reviews*. 22. 466-481. 10.1016/j.rser.2013.01.032.

LeCun, Y., Touresky, D., Hinton, G., & Sejnowski, T. (1988, June). A theoretical framework for back-propagation. In *Proceedings of the 1988 connectionist models summer school* (Vol. 1, pp. 21-28).

Géron, A. (2019). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media, Inc

Morcillo-Herrera, C., Hernández-Sánchez, F., & Flota-Bañuelos, M. (2014). Practical method to estimate energy potential generated by photovoltaic cells: Practice case at Merida City. *Energy Procedia*, 57, 245-254. doi: 10.1016/j.egypro.2014.10.029