



Prospective Energy Generation in Photovoltaic Systems, Based on the Comparison and Evaluation of Different Configurations Based on Artificial Neural Networks (ANN)

---

Ramos Cutipa José Manuel, Condori Yucra Reynaldo,  
Shuta Lloclla Henry, Chayña Velasquez Omar,  
Paredes Pareja Walter Oswaldo, Vilca Choque Mary Cymbel and  
Beltrán Castañón Norman Jesús

EasyChair preprints are intended for rapid dissemination of research results and are integrated with the rest of EasyChair.

October 24, 2022

# Prospectiva de generación energética en sistemas fotovoltaicos, a partir de la comparación y evaluación de diferentes configuraciones con fundamento en redes neuronales artificiales (RNA)

Ramos Cutipa, José Manuel, M.Sc.<sup>1</sup>, Condori Yucra, Reynaldo, M.Sc.<sup>2</sup>, Shuta Lloclla, Henry, M.Sc.<sup>1</sup>, Chayña Velasquez, Omar, M.Sc.<sup>1</sup>, Paredes Pareja, Walter Oswaldo, M.Sc.<sup>1</sup>, Vilca Choque, Mary Cymbel, Ing.<sup>2</sup>, Norman Beltrán<sup>1</sup>

<sup>1</sup>Universidad Nacional del Altiplano, Perú, jramos@unap.edu.pe, henryshuta@unap.edu.pe, ochayna@unap.edu.pe, walterparedes@unap.edu.pe, nbeltran@unap.edu.pe

<sup>2</sup>Universidad Nacional de Juliaca, Perú, rcondori@unaj.edu.pe, cymbelmar@gmail.com

*Resumen— Para que los sistemas fotovoltaicos sean sostenibles en el tiempo, es necesario tener un mejor aprovechamiento de la energía solar, por lo que se debe tener en cuenta al tomar decisiones, las predicciones probabilísticas de variables que influyen directamente en la producción de energía eléctrica. La irradiación solar es la variable importante para estas predicciones, la cual permite gestionar la producción de energía fotovoltaica. En el presente trabajo se plantea la aplicación de redes neuronales artificiales RNA configuradas adecuadamente para interactuar con la información que se dispone de variables climatológicas con el fin de poder predecir la irradiación solar. Se han analizado la correlación que existen entre estas variables para poder realizar la comparación de diferentes configuraciones de redes neuronales del tipo MLP para una variable y múltiples variables, además de utilizar redes neuronales recurrentes del tipo GRU. De acuerdo con el MAE las redes de tipo GRU son las que mejor resultados proveen, sin embargo, considerando la facilidad de entrenamiento las redes de tipo MLP son aceptables, siendo las de tipo multivariable las que mejor resultados dan. De cara al futuro, se plantea el uso de estas redes utilizando reconocimiento de patrones en las imágenes del cielo considerando el movimiento de las nubes y de la tierra respecto al sol.*

*Palabras clave—Predicción de energía, generador fotovoltaico, redes neuronales artificiales, modelamiento, irradiación.*

*Abstract— For photovoltaic systems to be sustainable in the time, it is necessary to have a better use of solar energy, so probabilistic predictions of variables that directly influence the production of electrical energy must be taken into account when making decisions. Solar irradiation is the important variable for these predictions, which allows managing the production of photovoltaic energy. In the present work, the application of RNA artificial neural networks properly configured to interact with the information that is available on climatological variables is proposed in order to be able to predict solar irradiation. The correlation that exists between these variables have been analyzed in order to be able to compare different configurations of MLP-type neural networks for one variable and multiple variables, in addition to using GRU-type recurrent neural networks. According to the MAE, the GRU type networks are the ones that provide the best results,*

*however, considering the ease of training, the MLP type networks are acceptable, being the multivariable type of the ones that give the best results. Looking to the future, the use of these networks using pattern recognition in sky images considering the movement of the clouds and the earth with respect to the sun is proposed.*

*Keywords— Energy prediction, photovoltaic generator, artificial neural networks, modelling, irradiation.*

## I. INTRODUCCIÓN

El sol es la fuente de energía que mayor aporte energético tiene en la tierra, esta energía es emitida en forma de radiaciones, con diferentes componentes en función de longitudes de onda, que es interceptada por la superficie de nuestro planeta, el aprovechamiento de esta radiación incidente se realiza utilizando celdas fotovoltaicas, los cuales son capaces de convertir la luz solar recibida en energía eléctrica [1], Existen diversas configuraciones para la conversión de esta energía, podemos mencionar entre los más usados, los sistemas autónomos que utilizan baterías para el almacenamiento de energía y los sistemas que inyectan energía directamente a la red, estos últimos se pueden instalar para generar energía eléctrica en el orden de los megavatios, llamándoles centrales solares fotovoltaicas.

Para que estos sistemas sean sostenibles, es necesario tener un mejor aprovechamiento de la energía solar, para lo cual es necesario tener en cuenta al tomar decisiones, las predicciones probabilísticas meteorológicas. Estas predicciones pueden tener un impacto en la mejora del rendimiento de los sistemas fotovoltaicos, por lo que resulta adecuado conocer de antemano la capacidad de producción de los sistemas, se recomienda realizar predicciones de radiación solar considerando en dos grupos bien diferenciados en función del horizonte de predicción o anticipación con la que se desea conocer la generación futura: predicciones a corto plazo con un horizonte de predicción de 24 a 48 horas y predicciones a muy corto plazo o predicciones inmediatas con las que se desea conocer las fluctuaciones de la generación de los sistemas fotovoltaicos con una antelación que va desde las 3 horas hasta periodos de unos pocos minutos. Estos

Digital Object Identifier: (only for full papers, inserted by LACCEI).

ISSN, ISBN: (to be inserted by LACCEI).

DO NOT REMOVE

horizontes de predicción responden a las necesidades de los sistemas eléctricos de conocer con la suficiente anticipación la capacidad de generación en función de la demanda y tratar de contribuir a la estabilidad de la red eléctrica limitando las fluctuaciones en la energía generada por los sistemas fotovoltaicos [2],

Los factores que se deben de tener en cuenta en la predicción de la radiación solar o irradiación ( $\text{kW-h/m}^2/\text{día}$ ), que podemos considerar como variables de entrada conjuntamente, la velocidad del viento ( $\text{m/s}$ ), temperatura mínima, media y máxima ( $^{\circ}\text{C}$ ), precipitación ( $\text{mm/ día}$ ) y humedad relativa (%), agregando el comportamiento de la radiación horizontal diaria del año anterior ( $\text{kWh/m}^2/\text{día}$ ), información que podemos recuperar de la base de datos de la NASA [3], En Diaz-Vico et. Al. [4], Martínez [5], se menciona que los sistemas fotovoltaicos ven afectados sus rendimientos, por tres factores principales, la irradiancia, la temperatura y la deposición de suciedad sobre los paneles fotovoltaicos. La velocidad del viento también es un factor que influye en la operación de estos sistemas [6]. La irradiancia es el factor principal debido a que el aprovechamiento de la célula solar (panel fotovoltaico) consiste en convertir la irradiancia en corriente eléctrica [7]. El valor la corriente extraída cambia en función de la irradiancia incidente en la célula solar, en consecuencia, la producción de energía eléctrica.

Se han desarrollado múltiples de trabajos de investigación, considerando diversas configuraciones de RNA orientadas la predicción de irradiancia, utilizando varios algoritmos de entrenamiento, así como en la predicción de la energía generada, pero no se ha considerado un estudio que evalué las diferentes configuraciones de redes neuronales artificiales propuestas para la predicción de variables que influyen directamente en los sistemas fotovoltaicos y por ende en la producción energética de los mismos, realizando una comparación entre estas, con el objetivo de determinar cuales tienen mejor comportamiento.

## II. TRABAJOS RELACIONADOS

### A. RNA Aplicadas a Predicción de Parámetros Solares

Una Red Neuronal Artificial (RNA), relaciona un sistema entre las entradas y las salidas, la cual está inspirada en el sistema nervioso, emulando al comportamiento de un cerebro humano, procesando información en paralelo, aprendiendo y generalizado. Son redes interconectadas masivamente en paralelo de otros elementos más simples, los cuales se adaptan y se organizan en forma jerárquica, con la finalidad de interactuar con su entorno, emulando un sistema nervioso biológico. Estas redes se basan en proceso de entrenamiento, con lo cual pueden resolver problemas y además tienen la capacidad de realizar predicciones [8], El elemento más básico en la neurona, el cual realiza cálculos a partir de un vector de entrada en cual preceder de otras neuronas o de una etapa exterior, proporcionado una única salida [9].

El crecimiento de la utilización de las energías renovables es notable, en el año 2018 se han agregado 181 GW a la capacidad instalada de energía renovable [10], El notable crecimiento de las energías renovables ha permitido introducir un creciente interés en la utilización de modelos de predicción, los cuales permiten predecir con un grado de importante de aproximación la potencia de generación de los sistemas de energía renovable, evaluados a intervalos de corto o largo plazo. Esto se puede apreciar especialmente en sistemas de energía solar fotovoltaica y eólica, en este tipo de energías la característica típica del recurso es intermitente, la radiación solar y velocidad del viento respectivamente [11], Es importante considerar que la predicción de la energía generada y la potencia eléctrica obtenida es crucial para los operadores de los sistemas interconectados, ya que proporcionarán la energía de equilibrio que satisfaga la demanda mediante las centrales eléctricas convencionales. Por lo tanto, implementar un modelo de predicción de alta precisión en el sistema de gestión de la red puede reducir el costo de producción energética [12], La predicción de la energía solar fotovoltaica se puede considerar desde dos puntos de vista, considerando predicciones basados en modelos y basados en datos [13], Los enfoques de predicción que utilizan los modelos emplean parámetros físicos, utilizando variables meteorológicas representativas como la radiación solar [14]. La utilización de estos modelos puede producir resultados precisos, sin embargo, la utilización de simplificaciones y suposiciones de los modelos pueden generar incertidumbres. Los enfoques basados en datos, por ejemplo, los algoritmos de aprendizaje automático utilizan una gran cantidad de datos de variables fotovoltaicas, en base a las cuales se construyen modelos del tipo caja negra, para realizar las predicciones de variables meteorológicas como la radiación solar [15].

En Jara et al. [16], se realiza una revisión de diversos algoritmos basados en máquinas de soporte vectorial aplicados a sistemas eléctricos, como son los sistemas de energías renovables, llegando a la conclusión de que las máquinas de soporte vectorial tienen bastantes aplicaciones, sin embargo, estos no han sido aplicados en su totalidad a los sistemas eléctricos, por lo que es posible identificar múltiples áreas de trabajos de investigación, también en Wolff et. al. [17], se ha comparado el modelo de regresión de vectores de soporte, con enfoques de modelado físico para la predicción de energía fotovoltaica. Las diferentes combinaciones de mediciones de potencia fotovoltaica, datos de predicciones meteorológicas numéricas y pronósticos de vector de movimiento de nubes las cuales se han considerado como entradas para el modelo de predicción. La precisión del modelo se evaluó recurriendo al error cuadrático medio y al error de sesgo medio, han concluido que este modelo tiene mejores resultados considerando estas tres variables.

En Malvoni et al. [18], investigaron la influencia de las técnicas de preprocesamiento de datos en la precisión de los métodos basados en datos utilizados para la predicción de energía fotovoltaica. Con este objetivo, se combinaron Wavelet Decomposition (WD) y PCA para descomponer los

datos meteorológicos de entrada. Se aplicó un método de Máquina de Vector de Soporte de Mínimos Cuadrados de Grupo (GLS-SVM) en un conjunto de datos que consiste en mediciones por hora de la potencia fotovoltaica y las variables climáticas (es decir, temperatura ambiente, irradiancia en el plano de la matriz y velocidad del viento) durante un día con las predicciones de energía fotovoltaica por delante. Los resultados mostraron que PCA-WD como técnica de preprocesamiento funciona mejor que cada PCA y WD únicos, y mejor que WD-PCA para un horizonte de predicción de una hora, en términos de error medio y distribución de probabilidad.

Wang et al. [19], investigaron el uso de diferentes componentes de radiación solar y temperaturas de celda derivados del modelado analítico fotovoltaico como entradas para el modelo de predicción. El modelo de predicción propuesto utilizó el Análisis de Componentes Principales para extraer los componentes principales de las variables climáticas, k-Vecino más cercano (k-NN) para clasificar el período de perdición en estudio en los períodos históricos con condiciones climáticas similares, y tres predicciones modelos (máquina de vectores de soporte (SVM), redes neuronales artificiales (ANN) y k ponderado-NN) para predecir la energía solar. La técnica de validación cruzada (CV) se utilizó, entonces, para determinar la distribución de errores de predicción a ajustar y, así, mejorar las predicciones finales. Los autores descubrieron que la utilización de características meteorológicas derivadas de modelos analíticos fotovoltaicos podría aumentar en gran medida la precisión de la predicción.

Eseye et al. [20], propuso un modelo de predicción híbrido que combina la Transformada Wavelet (WT), la Optimización del Enjambre de Partículas (PSO) y la Máquina de Vector de Soporte (SVM) para predicciones de energía fotovoltaica con 1 día de anticipación. El modelo se basa en mediciones reales de potencia fotovoltaica y PNT para radiación solar, temperatura ambiente, nubosidad, humedad, presión y velocidad del viento. Los resultados mostraron que el híbrido WT-PSO-SVM supera a otros modelos de predicción en términos de error de porcentaje absoluto medio (MAPE) y error absoluto medio normalizado (nMAE).

Liu et al. [21], desarrollaron un modelo de predicción de dos etapas basado en tres algoritmos ANN diferentes [Red neuronal de regresión generalizada (GRNN), Red neuronal de máquina de aprendizaje extremo (ELMNN) y Red neuronal Elman (ElmanNN)], combinados utilizando algoritmos genéticos optimizados. Algoritmo de propagación (GA-BP) para crear un modelo de modo de pronóstico de combinación de variación de peso (WVCFM) que estima los intervalos de predicción (PI) de la potencia fotovoltaica de 5 minutos por delante. Los autores utilizaron la irradiancia solar, la temperatura ambiente, el tipo de nube, el punto de rocío, la humedad relativa, el agua perceptible en el momento (t) y la producción de energía fotovoltaica en el momento (t - 1), como entradas, lo que indica que la correlación más fuerte se da entre la radiación solar y la energía fotovoltaica. producción.

En Al-Dahidi et al. [12], los autores propusieron un enfoque de conjunto completo basado en ANN para mejorar las predicciones de energía solar fotovoltaica con un día de anticipación. Se ha incorporado una técnica Bootstrap en el conjunto para cuantificar diferentes fuentes de incertidumbre que influyen en las predicciones mediante la estimación de las predicciones de intervalos. Se ha demostrado que el enfoque propuesto es superior a diferentes puntos de referencia al proporcionar predicciones de potencia precisas y cuantificar adecuadamente las posibles fuentes de incertidumbre.

Muhammad Ehsan et al. [22], propuso un modelo ANN multicapa basado en la percepción para la predicción de energía con 1 día de anticipación de una planta solar conectada a la red de 20 kW ubicada en la India. Los autores exploraron varios números de capas ocultas, funciones de activación de neuronas ocultas (p. Ej., Axon, LinearSigmoidAxon, etc.) y algoritmos de aprendizaje para actualizar los parámetros internos del modelo ANN durante su desarrollo (por ejemplo, gradiente conjugado, paso, momento, etc.) para obtener predicciones de potencia precisas con un día de anticipación. Los resultados mostraron que la RNA caracterizada por una capa oculta, Linear Sigmoid Axon como función de activación de neuronas, y Conjugate Gradient como algoritmo de aprendizaje, es capaz de proporcionar predicciones precisas de energía solar.

En Alomari et al. [23], propuso un modelo de predicción para la producción de energía solar fotovoltaica basado en ANN. El modelo propuesto exploró las capacidades de dos algoritmos de aprendizaje, a saber, Levenberg-Marquardt (LM) y Regularizaciones bayesianas (BR), utilizando diferentes combinaciones de la marca de tiempo y las características meteorológicas en tiempo real (es decir, temperatura ambiente y radiación solar global). Los resultados obtenidos mostraron que una combinación de la marca de tiempo y las dos variables meteorológicas utilizando el algoritmo BR es mejor que el algoritmo LM (RMSE = 0.0706 y 0.0753, respectivamente).

En este contexto, el objetivo del presente trabajo es desarrollar una ANN en la que se investigan diferentes algoritmos de aprendizaje y diferentes conjuntos de datos de entrenamiento (es decir, conjuntos de datos meteorológicos y de producción de energía fotovoltaica en tiempo real) para obtener una predicción de energía precisa con un día de anticipación con un tiempo computacional corto.

Según el conocimiento de los autores, no se han dedicado esfuerzos para investigar completamente el impacto de todos los algoritmos de aprendizaje de ANN disponibles en la precisión de las predicciones de producción de energía fotovoltaica junto con la investigación de las diferentes combinaciones de la marca de tiempo del año y las variables meteorológicas históricas (es decir, velocidad del viento, temperatura ambiente y radiación solar global) al tiempo que se incorporan las producciones históricas de energía fotovoltaica.

### III. LA PROPUESTA TÉCNICA

Aplicar diversas configuraciones de RNA y algoritmos de entrenamiento, para la predicción de irradiación solar, para que sea utilizada en la predicción de energía eléctrica generada en periodos cortos aplicados en sistemas de energía solar fotovoltaica, con lo que se podrá determinar las que mejor resultados presentan.

Revisar diversos trabajos de investigación, considerando diversas configuraciones de RNA orientadas a la predicción de irradiancia y energía generada.

Comparar el comportamiento de las diferentes configuraciones de RNA y algoritmos de entrenamiento, utilizando data generada de irradiación, temperatura, velocidad de viento, índice de claridad de insolación.

Analizar los resultados obtenidos, para determinar la configuración de RNA, con los que se obtengan mejores resultados de predicción, considerando variables de entrada adecuadas en los modelos, la cual permita mejorar las predicciones de potencia generada.

Para aplicar un modelo basado en la RNA, con la finalidad de pronosticar la irradiancia solar, es necesario recopilar una cantidad suficiente de datos meteorológicos.

La recolección de data de irradiancia, para la implementación de los algoritmos, se realiza mediante dos módulos fotovoltaicos monocristalinos modelo CNBM-120M de 120W con un ángulo de inclinación 15° orientado al Norte, los cuales están conectados en corto circuito para su medición con dos convertidores analógicos a señal de corriente de (4 a 20) mA modelo MRCA61BD, para la recolección de la data se utiliza un PLC de alta precisión modelo TM241 Schneider Electric, los datos se guardan en el equipo cada segundo, todos los días durante el periodo de investigación, logrando generar una data alrededor de 46800 datos por día.

La calibración del equipamiento para la medición de la irradiancia solar se realizó con la utilización del instrumento de medición portable polarímetro MAC-SOLAR SLM018c-2, fabricación alemana, utilizando la comparación directa con la corriente de corto circuito, con apoyo de métodos de regresión lineal, con lo cual se obtienen parámetros que permiten realizar el escalonamiento adecuado en la función implementadas en el PLC.

La corriente medida en corto circuito, se transforma en señal eléctrica de corriente en el rango de 4 a 20 mA, mediante el transductor de corriente, esta información es procesada por el PLC, por medio de un programa implementado en él, utilizando el lenguaje Ladder y diagrama secuencial mediante el programa SOMACHINE, con lo cual se obtiene la medición de la irradiancia en tiempo real y su almacenamiento en el PLC, con un intervalo de un segundo.

Se cuenta con una estación meteorológica, con lo cual se registran mediciones de temperatura ambiente, humedad relativa, velocidad de viento, esta información se adquiere, transmiten y registran continuamente en una base de datos.

También se ha utilizado la información de variables meteorológicas disponibles entre el 1 de enero del 2000 al 31

de diciembre del 2020, recabados del proyecto Power Data Acces Viewer de la NASA, data de libre acceso con fines de respaldar la energía renovable, la eficiencia energética de los edificios y las necesidades agrícolas, los cuales han sido validados con la información recabada por los sistemas de monitoreo.

Los datos recopilados no necesariamente son adecuados, por lo que se realiza un procesamiento previo antes de utilizarlos, lo que implica limpiar la data, agregar características, completar los valores faltantes entre otras.

El procedimiento implica verificar las lecturas de los sistemas de medición sean correctas, los errores que encuentran en este procesamiento son lecturas negativas, de irradiancia, temperatura, velocidad de viento, humedad relativa, por lo que para eliminar estas lecturas erróneas y reemplazarlas con valores adecuados es utilizar la interpolación de los puntos anteriores y posteriores [24].

Con el conjunto de datos previamente procesado, se determina el número de datos para el entrenamiento de la red neuronal, considerando para ello la irradiancia, variables climatológicas útiles, como son temperatura, velocidad de viento, humedad relativa, horas de sol durante el día, esta información sirve como variables de entrada a la red neuronal para la predicción de la irradiancia. Se ha utilizado el 80% de la base de datos seleccionados aleatoriamente para realizar los entrenamientos y el otro 20% para el procedimiento de validación y prueba [25], como variable de salida predicción de irradiancia.

El procedimiento para la selección de la configuración de la RNA, consiste en escoger el algoritmo adecuado de entrenamiento, selección de las funciones de activación que tengan mejor efecto en la configuración de la RNA y selección de la cantidad de neuronas en las capas ocultas con los mejores desempeños, en este proceso se probaron diferentes métodos para la selección del algoritmo de optimización de entrenamiento, considerando aquellos que menos errores presentan.

### IV. LAS CONTRIBUCIONES DEL TRABAJO

Para que los sistemas fotovoltaicos sean sostenibles, es necesario tener un mejor aprovechamiento de la energía solar, por lo que se debe tener en cuenta al tomar decisiones, las predicciones probabilísticas de variables que influyen directamente en la producción de energía eléctrica. De los múltiples trabajos de investigación revisados se considera a la irradiación entre las variables más importantes para estas predicciones, la cual permite gestionar la producción fotovoltaica. En el presente trabajo se ha planteado la utilización de redes neuronales artificiales configuradas adecuadamente para interactuar con la información que se dispone de variables climatológicas con el fin de poder predecir la irradiación. Se han analizado la correlación que existen entre estas variables para poder utilizarlas como entradas y con ello lograr realizar la comparación de diferentes configuraciones de redes neuronales del tipo MLP para una

variable y múltiples variables, además de utilizar redes neuronales recurrentes del tipo GRU.

De los ensayos realizados en los modelos de predicción utilizados en la presente investigación se han logrado configurar adecuadamente redes neuronales, para que puedan ser entrenados.

Se ha utilizado una red neuronal tipo FeedForward, la cual también es conocida como Multi Layer Perceptron (MLP), utilizando un método de activación tangente hiperbólica, esto porque los valores de previsión que entrega nuestra red están entre -1 y 1, se ha considerado de acuerdo con el análisis de correlación de variables, arquitecturas de una variable y multi variables, todas utilizando series temporales.

En el modelo de red neuronal de una variable, se ha considerado 7 neuronas de entrada en la primera capa, 1 capa oculta con 7 neuronas y capa de salida con 1 neurona, la función activación utilizada es la tangente hiperbólica, se ha utilizado como optimizador Adam y métricas de pérdidas Mean Absolute Error, la predicción obtenida es un valor continuo y no discreto, para calcular el Acuracy se utiliza la métrica Mean Squared Error, métrica que permite evaluar el entrenamiento de la red, considerando un valor adecuado para las épocas.

La red neuronal de serie temporal múltiples variables esta provista de 21 columnas con 7 pasos por 3 variables en la capa de entrada a la red, 1 capa oculta con 7 neuronas y capa de salida con 1 neurona, también se ha utilizado como función de activación la tangente hiperbólica, optimizador Adam y métricas de pérdidas Mean Absolute Error.

La red neural Gated Recurrent Unit (GRU), esta provista de una capa de entrada, una capa GRU y una capa densa de salida.

En todos los casos analizados se devuelve como resultado la variable irradiación, información que es utilizada para poder gestionar sistemas de generación fotovoltaica.

## V. RESULTADOS Y DISCUSIONES

### A. Análisis de Correlación

Luego de analizar el conjunto de datos, con lo cual realizamos el entrenamiento de nuestra red neuronal, se ha determinado el grado de correlación que se tiene entre las variables consideradas, se observa en el resultado del análisis que existe un nivel de correlación es de 0.29 entre la radiación y la temperatura, el nivel de correlación entre la irradiación y con respecto al índice de claridad de insolación es de 0.66. Para el resto de las variables podemos asumir que el nivel de correlación es muy bajo y que realmente no aportan información útil para realizar las predicciones de los niveles de radiación.

Además, se ha verificado que existe una tendencia estacionaria a lo largo de los años del conjunto de datos, esta particularidad facilita el pronóstico. En las figuras 2 y 3 se puede apreciar estas tendencias para la variable de irradiación.

Es importante mencionar que la irradiación es la variable que más influye en los sistemas de generación fotovoltaica.

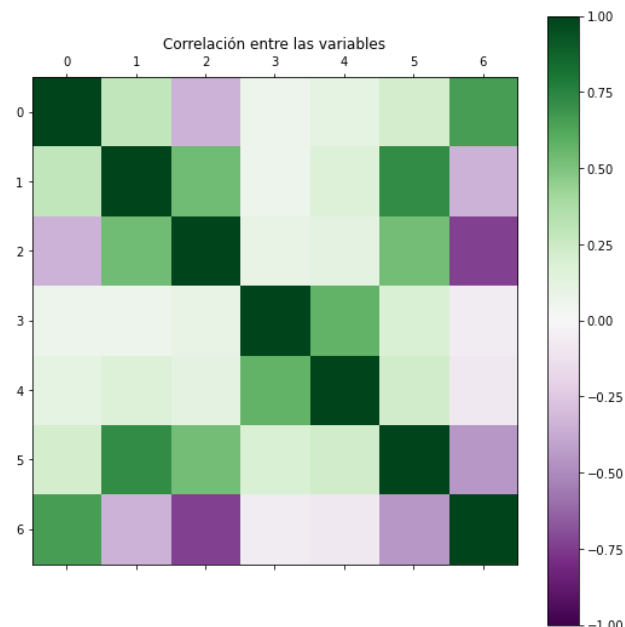


Fig. 1 Resultados de la correlación de variables del conjunto de datos analizados




Fig. 2. Comparación de promedios mensuales de la irradiación para los años 2000 a 2020.




Fig. 3. Irradiación diaria desde el año 2000 hasta el año 2020.

### B. Red Neuronal Tipo MLP de una Variable.

Al ser la irradiación, la variable que está muy relacionada con la producción de energía fotovoltaica se ha considera en primer análisis una red neuronal del tipo MLP que considera a esta variable como entrada, los resultados de comparación entre el conjunto de prueba y las predicciones realizadas se muestran en la Figura 4, la gráfica de color anaranjado representa los resultados obtenidos y la gráfica de color azul representa los valores reales de irradiación del conjunto de pruebas.

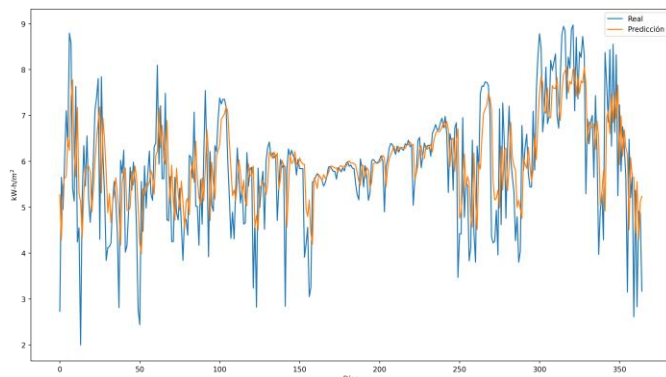


Fig. 4. Predicciones realizadas versus valores del conjunto de pruebas.

En la tabla I, se muestran los resultados de comparación de datos reales tomados del conjunto de prueba y los resultados obtenidos de la predicción.

TABLA I  
COMPARACIÓN DE VALORES DEL CONJUNTO DE VALIDACIÓN CON LOS VALORES PREDICHOS POR NUESTRA RED NEURONAL

	Real	Predicción	Diferencia
0	2.73	5.35	-2.62
1	5.65	4.79	0.85
2	4.95	5.45	-0.50
3	6.03	5.48	0.54
4	7.10	5.75	1.34
5	6.32	6.72	-0.39
6	8.79	6.25	2.53
7	8.57	7.28	1.28
8	5.41	7.68	-2.27
9	5.13	5.98	-0.85

### C. Red Neuronal Tipo MLP Multi Variable

En la red neuronal anterior se ha considerado como única variable de entrenamiento la irradiación, sin embargo, al correlacionar las variables del conjunto de datos, se verifica que las variables de temperatura y el índice de claridad de insolación están correlacionadas con la irradiación, por lo que se ha realizado las modificaciones necesarias para entrenar nuestra red neuronal, considerando como entradas a las variables de temperatura, índice de claridad de insolación y la irradiación, los resultados se muestran en la figura 5, la gráfica de color anaranjado representa los resultados obtenidos y la gráfica de color azul representa los valores reales de irradiación del conjunto de pruebas.

gráfica de color azul representa los valores reales de irradiación del conjunto de pruebas.




Fig. 5. Comparación de las predicciones con respecto al conjunto de pruebas red neuronal multivariable.

En la Tabla II se muestra la comparación de los datos reales tomados del conjunto de prueba y los resultados obtenidos de la predicción para los primeros diez predicciones.

TABLA II  
COMPARACIÓN DE LOS RESULTADOS OBTENIDOS DE LA RED NEURONAL MULTIVARIABLE CON LOS DEL CONJUNTO DE VALIDACIÓN PARA LA IRRADIACIÓN.

	Real	Predicción	Diferencia
0	2.73	5.23	-2.50
1	5.65	5.04	0.61
2	4.95	5.48	-0.53
3	6.03	5.37	0.65
4	7.10	5.61	1.49
5	6.32	6.53	-0.21
6	8.79	5.99	2.79
7	8.57	7.40	1.16
8	5.41	7.67	-2.26
9	5.13	5.62	0.49

### D. Red Neuronal Tipo MLP con Embeddins

Se ha analizado una red neuronal para series temporales con Embeddings, con la finalidad de dar una valoración útil a algunos datos categóricos, en este caso se ha considerado dos grupos característicos, las semanas que se dividen en siete días y los meses, los que serían una especie de subred neuronal dentro de la red principal, variable que se ha utilizado es la irradiación, los resultados se muestran en la figura 6, la gráfica de color anaranjado representa los resultados obtenidos y la gráfica de color azul representa los valores reales de irradiación del conjunto de pruebas.

### E. Red Neuronal Tipo GRU

Las redes neuronales GRU (Gated recurrent unit) son un tipo de redes recurrentes diseñadas para el análisis de series temporales, esta red fue entrenada con las variables de irradiancia, temperatura y el índice de claridad de insolación.




Fig. 6. Predicciones red neuronal con Embeddings.

Los resultados de las predicciones realizadas por la red neuronal GRU se muestra en la Figura 7, la gráfica de color anaranjado representa los resultados obtenidos y la gráfica de color azul representa los valores reales de irradiación del conjunto de entrenamiento, la gráfica de color verde es el conjunto objetivo.




Fig. 7 Predicciones de la red neuronal GRU

#### F. Comparación de Métricas.

En la tabla III, se muestran las diferencias obtenidas en el proceso de entrenamiento de las configuraciones de redes neuronales analizadas.

TABLA III  
VALORES FINALES DE MÉTRICAS DE LAS REDES NEURONALES UTILIZADAS

Modelo	loss	val_loss
Red neuronal de una variable	0.1583	0.1752
Red neuronal multivariable	0.1625	0.1703
Red neuronal con embeddings	0.1878	0.1898
Red neuronal GRU	0.0935	0.0923

## VI. DISCUSIÓN

El análisis del conjunto de datos de las variables disponibles considerando el grado de correlación entre ellas, dio como resultado que se tiene una correlación entre la irradiación y temperatura, como también con el índice de claridad de insolación. En [26] ha desarrollado una metodología confiable para poder determinar el comportamiento y la relación entre la irradiación y la temperatura, los cuales son parámetros meteorológicos

característicos utilizados como fuente primaria utilizados en los sistemas solares térmicos y fotovoltaicos. Se considera como parámetro importante relacionado con la componente directa y difusa de la radiación solar al índice de claridad, factor muy importante en la ingeniería solar [27], estos resultados están en concordancia con los resultados que obtuvimos.

La utilización de diferentes configuraciones de las redes neuronales artificiales, han permitido realizar las predicciones de la irradiación, variable muy importante en los sistemas de generación fotovoltaica, los cuales han sido validados con un grado de certeza aceptable, estos resultados son muy similares a los obtenidos por Muhammad Ehsan et. al. [22] que propuso un modelo ANN multicapa basado en la percepción para la predicción de energía con 1 día de anticipación de una planta solar conectada a la red de 20 kW ubicada en la India. Alomari et. al. [23] desarrollaron un modelo de predicción para la producción de energía solar fotovoltaica basado en ANN, utilizando diferentes combinaciones de la marca de tiempo y las características meteorológicas en tiempo real. Las redes neuronales se basan en proceso de entrenamiento, con lo cual pueden resolver problemas y además tienen la capacidad de realizar predicciones [8], estos procesos de entrenamiento y adecuación de los datos han permitido lograr las predicciones de la irradiación

Se ha considerado en el desarrollo de la investigación la comparación del desempeño una red neuronal del tipo Multi Layer Perceptron, en tres variantes. La primera considerando solo una en este caso la irradiación. La segunda es una red multivariable que utiliza los datos de la irradiación, temperatura y índice de claridad de insolación, variables que han sido escogidas por su grado de correlación entre ellas. La tercera utiliza dos embeddings de la variable irradiación. Se ha utilizado también una red neuronal recurrente GRU, el cual ha utilizado las tres variables meteorológicas consideradas en este estudio, las métricas obtenidas sugieren que los resultados de predicción obtenidas son aceptables. Los valores obtenidos de la métrica función de pérdida del conjunto de entrenamiento son de 0.1583, 0.1625, 0.1878 y 0.0935 para los cuatro tipos de redes analizadas y para el conjunto de validación es de 0.1752, 0.1703, 0.1898 y 0.0923 respectivamente.

La red neuronal que mejores resultados tuvo, fue la del tipo recurrente GRU obteniendo métricas para la MSE de 0.0935 y 0.0923 para los conjuntos de entrenamiento y validación respectivamente, estos resultados son concordantes con los obtenidos por [23] los cuales son 0.0706 y 0.0753, respectivamente, dicha métrica la obtuvo utilizando una red ANN. Sin embargo, las que mejor resultado obtuvieron desde el punto de vista de predecir el valor de la irradiación diaria, han sido las redes multi layer perceptron multivariable, que en promedio para las predicciones realizadas durante 365 días fue de 5.92 KW-hr/día comparado con el promedio de valores reales de 5.88 KW-hr/día, siendo el error de 0.04 KW-hr/día.



## VII. CONCLUSIONES

Los algoritmos de aprendizaje automático, especialmente las redes neuronales artificiales, han demostrado ser una gran herramienta para resolver problemas de predicción de series de tiempo, como la predicción de la irradiación solar.

El análisis del grado de correlación entre las variables del conjunto de datos dio como resultado, que se tiene una correlación entre la irradiación y temperatura, como también con el índice de claridad de insolación.

De los ensayos realizados en los modelos de predicción utilizados en la presente investigación se han logrado configurar adecuadamente redes neuronales artificiales, para que puedan ser entrenados y predecir la irradiación.

Los algoritmos pudieron pronosticar con éxito la irradiación solar del siguiente día, especialmente en los días con índices de claridad altos.

Bajo los parámetros de pérdida y validación de esta última, la red neuronal GRU dio como resultado valores inferiores a 0.1 por lo que se concluye como mejor en este aspecto. Sin embargo, si consideramos al tiempo como parámetro prioritario la red MLP requiere menos tiempo de entrenamiento que la GRU.

Las redes MLP produjo los mejores resultados de este pronóstico a pesar de que se esperaba que las redes recurrentes GRU fuera el mejor predictor, ya que se usan ampliamente en el pronóstico de series de tiempo.

Dentro de las redes MLP analizadas, la red MLP multivariable fue la que mejores resultados produjo

## AGRADECIMIENTO

Nuestro agradecimiento especial al Grupo de Investigación y Desarrollo en Tecnología Solar Fotovoltaica (GRIDSOLAR), de la Universidad Nacional de Juliaca, de la cual se participó con el Proyecto "Diseño y Validación de la Operación y Monitoreo de Sistemas Fotovoltaicos Conectados a la Red (SFRCs) en Condiciones Extremas del Altiplano sobre los 3800 msnm" y a los investigadores del Instituto de Investigación en Energía, Automatización Eléctrica y Mecánica (ENAEM) de la Universidad Nacional del Altiplano Puno.

## REFERENCIAS

[1] G. M. Molina and H. C. Melchor, "Prototipo de un sistema fotovoltaico autónomo," *Apl. la Ing.*, vol. 3, no. 8, pp. 9–18, 2016, [Online]. Available: [http://www.ecorfan.org/bolivia/researchjournals/Aplicaciones\\_de\\_la\\_Ingenieria/vol3num8/Revista\\_Aplicaciones\\_de\\_la\\_Ingenieria\\_V3\\_N8\\_2.pdf](http://www.ecorfan.org/bolivia/researchjournals/Aplicaciones_de_la_Ingenieria/vol3num8/Revista_Aplicaciones_de_la_Ingenieria_V3_N8_2.pdf).

[2] C. Santos Burguete, D. Masa Bote, A. C. Do Amaral Burghi, T. Hirsch, and R. Pitz-Paal, "Aplicaciones en energía solar," in *Física del caos en la predicción meteorológica*, Agencia Estatal de Meteorología, 2018, pp. 599–606.

[3] L. C. Ruiz Cárdenas, D. Amaya Hurtado, and R. Jiménez Moreno, "Predicción de radiación solar mediante deep belief network," *Rev.*

*Tecnura*, vol. 20, no. 47, p. 39, 2016, doi: 10.14483/udistrital.jour.tecnura.2016.1.a.03

[4] D. Díaz-Vico, A. Torres-Barrán, A. Omari, and J. R. Dorransoro, "Deep Neural Networks for Wind and Solar Energy Prediction," *Neural Process. Lett.*, vol. 46, no. 3, pp. 829–844, 2017, doi: 10.1007/s11063-017-9613-7

[5] I. C. Pérez Martínez, "Fabricación de células solares de perovskita en condiciones ambientales," 2019.

[6] T. Khatib and W. Elmenreich, *Modeling of photovoltaic systems using Matlab: Simplified green codes*. 2016.

[7] O. Perpiñan Lamigueiro, *Energía solar fotovoltaica*. Creative Commons ebook, 2012.

[8] E. Acevedo, Eder; Serna, Alexei; Serna, "Principiosy características de las redes neuronales artificiales," *Desarro. e innovación en Ing.*, no. March 2019, pp. 173–182, 2017, [Online]. Available: [https://www.researchgate.net/profile/Edgar\\_Serna\\_M/publication/331385353\\_Desarrollo\\_e\\_innovacion\\_en\\_ingenieria\\_ed\\_2/links/5c76e4ce92851c69504663b5/Desarrollo-e-innovacion-en-ingenieria-ed-2.pdf#page=379](https://www.researchgate.net/profile/Edgar_Serna_M/publication/331385353_Desarrollo_e_innovacion_en_ingenieria_ed_2/links/5c76e4ce92851c69504663b5/Desarrollo-e-innovacion-en-ingenieria-ed-2.pdf#page=379).

[9] M. S. Olarte T., "Nuevos modelos de predicción a corto plazo de la generación eléctrica en plantas basadas en energía solar fotovoltaica," 2017.

[10] M. Mussetta et al., "Assessment of Artificial Neural Networks Learning Algorithms and Training Datasets for Solar Photovoltaic Power Production Prediction," *Front. Energy Res.* | [www.frontiersin.org](http://www.frontiersin.org), vol. 7, p. 130, 2019, doi: 10.3389/fenrg.2019.00130.

[11] A. Nespoli et al., "Day-Ahead Photovoltaic Forecasting: A Comparison of the Most Effective Techniques," *Energies*, vol. 12:1621, 2019, doi: 10.3390/en12091621.

[12] S. Al-Dahidi, O. Ayadi, M. Alrbai, and J. Adeeb, "Ensemble approach of optimized artificial neural networks for solar photovoltaic power prediction," *IEEE Access*, vol. 7, pp. 81741–81758, 2019, doi: 10.1109/ACCESS.2019.2923905.

[13] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. J. Martinez-de-Pison, and F. Antonanzas-Torres, "Review of photovoltaic power forecasting," *Sol. Energy*, vol. 136, pp. 78–111, Oct. 2016, doi: 10.1016/j.solener.2016.06.069.

[14] M. K. Behera, I. Majumder, and N. Nayak, "Solar photovoltaic power forecasting using optimized modified extreme learning machine technique," *Eng. Sci. Technol. an Int. J.*, vol. 21, no. 3, pp. 428–438, Jun. 2018, doi: 10.1016/j.jestch.2018.04.013.

[15] C. Monteiro, L. A. Fernandez-Jimenez, I. J. Ramirez-Rosado, A. Muñoz-Jimenez, and P. M. Lara-Santillan, "Short-Term Forecasting Models for Photovoltaic Plants: Analytical versus Soft-Computing Techniques," *Math. Probl. Eng.*, vol. 2013, p. 767284, 2013, doi: 10.1155/2013/767284.

[16] J. Jara E., D. Giral, and F. Martínez S., "Implementation of algorithms based on support vector machine (SVM) for electric systems topic review," *Tecnura*, vol. 20, no. 48, pp. 149–170, 2016, doi: 10.14483/udistrital.jour.tecnura.2016.2.a.11.

[17] B. Wolff, J. Sauer, O. Kramer, and J. Parisi, "Support Vector Regression for Solar Power Prediction," 2017.

[18] M. Malvoni, M. G. De Giorgi, and P. M. Congedo, "Forecasting of PV Power Generation using weather input data-preprocessing techniques," *Energy Procedia*, vol. 126, pp. 651–658, 2017, doi: 10.1016/j.egypro.2017.08.293.

[19] J. Wang, H. Zhong, X. Lai, Q. Xia, Y. Wang, and C. Kang, "Exploring key weather factors from analytical modeling toward improved solar power forecasting," *IEEE Trans. Smart Grid*, vol. 10, no. 2, pp. 1417–1427, Mar. 2019, doi: 10.1109/TSG.2017.2766022.

[20] A. T. Eseye, J. Zhang, and D. Zheng, "Short-term photovoltaic solar power forecasting using a hybrid Wavelet-PSO-SVM model based on SCADA and Meteorological information," *Renew. Energy*, vol. 118, pp. 357–367, Apr. 2018, doi: 10.1016/j.renene.2017.11.011.

[21] L. Liu et al., "Prediction of short-term PV power output and uncertainty analysis," *Appl. Energy*, vol. 228, pp. 700–711, Oct. 2018, doi: 10.1016/j.apenergy.2018.06.112.

[22] R. Muhammad Ehsan, S. P. Simon, and P. R. Venkateswaran, "Day-ahead forecasting of solar photovoltaic output power using multilayer perceptron," *Neural Comput. Appl.*, vol. 28, no. 12, pp. 3981–3992, Dec. 2017, doi: 10.1007/s00521-016-2310-z.

[23] M. H. Alomari, O. Younis, and S. M. A. Hayajneh, "A Predictive Model for Solar Photovoltaic Power using the Levenberg-Marquardt and

- Bayesian Regularization Algorithms and Real-Time Weather Data,” 2018. Accessed: May 04, 2021. [Online]. Available: [www.ijacsa.thesai.org](http://www.ijacsa.thesai.org).
- [24] A. Alzahrani, P. Shamsi, C. Dagli, and M. Ferdowsi, “Solar Irradiance Forecasting Using Deep Neural Networks,” *Sci. Procedia Comput. Sci.*, vol. 114, pp. 304–313, 2017, doi: 10.1016/j.procs.2017.09.045.
- [25] A. Moo, E. J. de, A. Bassam, and O. Outmane, “Estimación de irradiancia empleando redes neuronales artificiales con variables meteorológicas y eléctricas de módulos fotovoltaicos Estimation of irradiance using artificial neural networks with meteorological and electrical variables of photovoltaic modules,” 2016.
- [26] J. Hernández, C. Trujillo, and W. Vallejo, “Modelamiento de la irradiancia y la temperatura ambiente utilizando funciones de probabilidad Irradiation and ambient-temperature model using probability functions,” vol. 18, no. 39, pp. 128–137, 2014.
- [27] N. R. Flores R. and M. A. Domínguez R., “Medición de la eficiencia energética de los paneles solares de silicio,” 2019.