

**PRONÓSTICO DEL RECURSO SOLAR A CORTO PLAZO PARA DISTRITOS
INDUSTRIALES BASADO EN REDES NEURONALES ARTIFICIALES**

**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE QUITO**

**CARRERA:
INGENIERÍA ELÉCTRICA**

**Trabajo de titulación previo a la obtención del título de
INGENIERO ELÉCTRICO**

TEMA:

**PRONÓSTICO DEL RECURSO SOLAR A CORTO PLAZO PARA
DISTRITOS INDUSTRIALES BASADO EN REDES NEURONALES
ARTIFICIALES**

**AUTOR:
FABRICIO ANDRES CARRILLO ANDRADE**

**TUTOR:
ALEX DAVID VALENZUELA SANTILLAN**

Quito D.M., febrero 2022

Fabricio Andres Carrillo Andrade

PRONÓSTICO DEL RECURSO SOLAR A CORTO PLAZO PARA DISTRITOS INDUSTRIALES BASADO EN REDES NEURONALES ARTIFICIALES

Universidad Politécnica Salesiana, Quito – Ecuador 2022

Ingeniería Eléctrica

Breve reseña histórica e información de contacto.



Fabricio Andres Carrillo Andrade (Y'1996 – M'13). Realizó sus estudios secundarios en la Instituto Tecnológico Superior Policía Nacional de la ciudad de Quito. Egresado de Ingeniería eléctrica de la Universidad Politécnica Salesiana. Su trabajo se basa en el Pronóstico del recurso solar a corto plazo para distritos industriales basado en redes neuronales artificiales. fcarrilloa1@est.ups.edu.ec

Dirigido por:



Alex David Valenzuela Santillán (Y'1989 – M'12). Realizó sus estudios superiores en la Escuela Politécnica Nacional de Quito, donde se graduó de Ingeniero Eléctrico en diciembre 2013, Además realizó estudios de maestría en Newcastle University en el Reino Unido, donde obtuvo el título en Power Distribution Engineering MSc. Actualmente es profesor ocasional tiempo completo de la Universidad Politécnica Salesiana. avalenzuela@ups.edu.ec

Todos los derechos reservados:

Queda prohibida, salvo excepción prevista en la ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con la autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos o investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS ©2022
Universidad Politécnica Salesiana
QUITO – ECUADOR

DECLARATORIA DE COAUTORÍA DEL DOCENTE TUTOR/A

Yo, Alex David Valenzuela Santillán declaro que bajo mi dirección y asesoría fue desarrollado el trabajo de titulación, Pronóstico Del Recurso Solar A Corto Plazo Para Distritos Industriales Basado En Redes Neuronales Artificiales realizado por Fabricio Andres Carrillo Andrade, obteniendo un producto que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana para ser considerado como trabajo final de titulación.

Quito D.M., febrero de 2022



.....

Alex David Valenzuela Santillán


C.C.: 1721848644

CESIÓN DE DERECHOS DE AUTOR

Yo, Fabricio Andres Carrillo Andrade, con documento de identificación N° 1725275505, manifiesto mi voluntad y cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del trabajo de grado/titulación intitulado: Pronóstico Del Recurso Solar A Corto Plazo Para Distritos Industriales Basado En Redes Neuronales Artificiales, mismo que ha sido desarrollado para optar por el título de: Ingeniería Eléctrica, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en mi condición de autor me reservo los derechos morales de la obra antes citada. En concordancia, suscribo este documento en el momento que hago entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito D.M., febrero 2022



.....
Fabricio Andres Carrillo Andrade
C.C.: 1725275505

ÍNDICE GENERAL

1.	Introducción.....	12
2.	Marco teórico.....	13
2.1	Pronóstico del recurso fotovoltaico	13
2.2	Sistema fotovoltaico	13
2.2.1	Partes del sistema fotovoltaico	13
3.	Variables meteorológicas	14
3.1	Radiación solar	14
3.2	Herramientas de predicción solar	14
3.3	Herramientas para medir datos en tiempo real	14
3.4	Herramientas de métodos y modelos.....	14
4.	Metodología para el pronóstico de radiación solar.....	14
4.1	Sistema de variables a corto plazo.....	15
4.2	Sistema de variables a mediano plazo	15
4.3	Sistema de variables a largo plazo.....	15
5.	Redes neuronales artificiales	16
5.1	Características de redes neuronales artificiales	16
5.2	Estructura básica de una red neuronal	16
5.3	Tipos de capas	17
5.3.1	Capa unicapa.....	17
5.3.1.1	Entrenamiento y aprendizaje de capa neuronal unicapa.....	17
5.3.2	Capa multicapa	17
5.3.2.1	Aprendizaje y entrenamiento de capas neuronales multicapas	17
6.	Programación y entrenamiento de redes neuronales artificiales	17
6.1	Arquitectura	18
6.2	Sistemas expertos	18
7.	Implementación de los algoritmos y simulación en matlab	18
7.1	Pronóstico de radiación solar.....	18
7.2	Creación de un módulo fotovoltaico en Matlab/Simulink.....	19
8.	Análisis de resultados	21
8.1	Análisis trimestral.....	22
8.2	Análisis mensual.....	24
8.3	Análisis diario.....	25

8.4	Simulación de un módulo fotovoltaico completo.....	26
9.	Conclusión	28
9.1	Trabajos futuros.....	29
10.	Referencias	30
10.1	Matriz de Estado del Arte.....	32
10.2	Resumen de Indicadores.....	37

ÍNDICE DE FIGURAS

Figura 1. Esquema Unicapa.	17
Figura 2. Esquema Multicapa.	17
Figura 3. Circuito fotovoltaico con resistencia serie y paralelo.	19
Figura 4. Punto de Máxima Potencia.	21
Figura 5. Radiación medida frente a pronosticada de enero 1 a marzo 31.	22
Figura 6. Error absoluto de enero 1 a marzo 31.	22
Figura 7. Error relativo de enero 1 a marzo 31.	22
Figura 8. Radiación medida frente a pronosticada de abril 1 a junio 31.	22
Figura 9. Error absoluto de abril 1 a junio 31.	22
Figura 10. Error relativo de abril 1 a junio 31.	23
Figura 11. Radiación medida frente a pronosticada de julio 1 a septiembre 30.	23
Figura 12. Error absoluto de julio 1 a septiembre 30.	23
Figura 13. Error relativo de julio 1 a septiembre 30.	23
Figura 14. Radiación medida frente a pronosticada de octubre 1 a diciembre 31.	23
Figura 15. Error absoluto octubre 1 a diciembre 31.	23
Figura 16. Error relativo octubre 1 a diciembre 31.	24
Figura 17. Radiación medida frente a pronosticada del mes de agosto.	24
Figura 18. Error mensual del mes de agosto.	24
Figura 19. Error relativo del mes de agosto.	24
Figura 20. Radiación medida frente a pronosticada mes de agosto 16 de 00:00 a 23:30.	25
Figura 21. Error diario del mes de agosto día 16 de 00:00 a 23:30.	25
Figura 22. agosto día 16 de 00:00 a 23:30.	25
Figura 23. Pronostico de potencia a las 6:30.	27
Figura 24. Pronostico de potencia a las 8:00.	27
Figura 25. Pronostico de potencia a las 9:30.	27
Figura 26. Pronostico de potencia a las 11:00.	27
Figura 27. Pronostico de potencia a las 12:30.	27
Figura 28. Pronostico de potencia a las 14:00.	27
Figura 29. Pronostico de potencia a las 15:30.	27
Figura 30. Pronostico de potencia a las 17:00.	27
Figura 31. Pronostico de potencia a las 18:30.	28
Figura 32. Resumen e indicador de la temática - Estado del arte.	37

Figura 33. Indicador de formulación del problema - Estado del arte.....	38
Figura 34. Indicador de solución - Estado del arte.....	39

ÍNDICE DE TABLAS

Tabla 1. Resultados de los datos de validación Levenberg-Marquardt.	19
Tabla 2. Resultados de los datos de validación de Regularización Bayesiana.	19
Tabla 3. Resultados de los datos de Gradiente de Escala Conjugada.	19
Tabla 4. Datos proporcionados por el fabricante.	19
Tabla 5. Fechas de las estaciones meteorológicas.	21
Tabla 6. Valores de datos reales frente a pronosticado.	26
Tabla 7. Valores obtenidos de potencia de pronóstico de valores reales y pronóstico de valores de radiación solar.	28

PRONÓSTICO DEL RECURSO SOLAR A CORTO PLAZO PARA DISTRITOS INDUSTRIALES BASADO EN REDES NEURONALES ARTIFICIALES

Resumen

La energía tradicional y la no contaminante es un tema relevante para la humanidad debido a su crecimiento exponencial en los últimos años y a la necesidad que se tiene de la energía. Conociendo que la mayor fuente de energía que se dispone es la energía solar debemos aprovechar este recurso para así crear energías renovables que pueda sustituir a las no renovables y de paso disminuir las emisiones de gases a la atmosfera.

Para un óptimo aprovechamiento se usarán sistemas fotovoltaicos y fototérmicos lo que conlleva la necesidad de un amplio conocimiento sobre la radiación solar que impacta la corteza terrestre, considerando que estos valores cambian en cuestión de horas, días o meses dependiendo de su latitud y los microclimas de cada zona. Para esta investigación expondremos el entrenamiento de una red neuronal artificial basado en multicapas para predecir un horizonte a corto plazo de radiación solar.

Los modelos que consideramos varían de acuerdo al algoritmo utilizado para entrenar a la red neuronal artificial y esto hace que tengamos diferentes valores de potencia en la simulación de un módulo fotovoltaico.

Palabras Clave: Radiación solar, energía renovable, sistemas fotovoltaicos, predicción.

Abstract

Traditional and non-polluting energy is a relevant issue for humanity due to its exponential growth in recent years and the need for energy. Knowing that the largest source of energy available is solar energy, we must take advantage of this resource in order to create renewable energies that can replace non-renewable ones and, incidentally, reduce gas emissions into the atmosphere.

For optimal use, photovoltaic and photothermal systems will be used, which entails the need for extensive knowledge about solar radiation that reaches the earth's surface, considering that these values change in a matter of hours, days or months depending on its latitude and the microclimates of each zone. For this research we will expose the training of an artificial neural network based on multilayers to predict a short-term horizon of solar radiation.

The models that we consider vary according to the algorithm used in the training of an artificial neural network and this means that we have different power values in the simulation of a photovoltaic module.

Keywords: Solar radiation, renewable energy, photovoltaic systems, prediction.

1. Introducción

Con el pasar del tiempo la conversión de energía ha tomado un punto muy importante pues con el aumento poblacional el uso de esta energía excede los límites de consumo y la demanda de la misma aumenta notablemente, en la actualidad las fuentes de energía no renovable abarcan el 78.3 % aquellas que están basadas al uso de carbón petróleo y gas natural mientras que el (19.1%) es echa a base de energía renovable y solo el (2.6%) de energía nuclear. [1].

Los inconvenientes que existen al momento de utilizar recursos fósiles no renovables son la existencia de nuevos reservorios que resultan ser de muy difícil acceso, y en ciertos casos suelen ser caros de explotar, además se debe considerar que son recursos finitos que se van agotando y solo se encuentran en ciertas localidades por lo que se puede dar conflictos militares y políticos además del impacto ambiental que su extracción ocasiona.

Con todos estos aspectos climáticos y aspectos negativos para el medio ambiente trae consecuencias y en la actualidad empiezan a renacer los nuevos sistemas tecnológicos que se basan en energía que se considera renovable en la elaboración y producción de electricidad y calor todo esto con la finalidad de mejorar el estilo de vida de las personas con medidas de ayuda al medio ambiente y con esto la principal energía que puede ayudar a mejorar el ambiente es la energía solar puesto que es recibida en nuestro planeta alrededor de 10000 veces con lo que se considera superior al consumo de la energía eléctrica común.

Por lo tanto, la energía solar es presentada como un recurso de mucha importancia para poder cambiar las fuentes de energía no renovables y así poder disminuir la cantidad de CO₂ de la atmosfera, ya que existen diferentes

métodos para atrapar y convertir la energía solar especialmente a través de sistemas fotovoltaicos y los sistemas fototérmicos.

Por lo tanto, un método fotovoltaico ayuda a modificar la energía solar en energía eléctrica, además ayudan a la iluminación, refrigeración, bombeo y se considera que un sistema fototérmico ayuda a la absorción del calor y lo transfiere a otro ambiente como puede ser el agua o el aire, también se incluye los sistemas de calentamiento pasivo y los sistemas de desinfección, desintoxicación y desalación del agua [1].

En la creación de un patrón de predicción de potencia fotovoltaica a corto plazo se toma en cuenta la energía del sol pues es una de las fuentes renovables más grandes e importantes, con base se puede realizar los modelos de predicción mediante la radiación solar puesto que es importante para el diseño, el desarrollo y a su vez la optimización de aplicaciones como lo son los sistemas fotovoltaicos [2]. Cada una de las predicciones que se pueden generar por otros modelos como los atmosféricos ayudan a predecir el clima y a partir de dichas predicciones de variables como velocidad, precipitaciones, presión, dirección del viento, temperatura, cobertura de nubes y radiación solar, fruto de estos modelos atmosféricos, se calcula la predicción de la potencia eléctrica generada en un parque solar por aproximaciones estadísticas o físicas [3].

Por las limitaciones de los modelos de predicción y la producción eléctrica que se obtiene al principio, no pueden optimizar la predicción de dichos modelos atmosféricos ya que cae en errores que son causados por un modelado defectuoso de la zona o a su vez por condiciones iniciales defectuosas provocan importantes diferencias entre el pronóstico y la realidad.

2. Marco teórico

2.1 Pronóstico del recurso fotovoltaico

El pronóstico de los recursos fotovoltaicos depende de los datos recogidos en las estaciones meteorológicas, mismos que sirven para predecir la radiación solar para utilizar esta generación renovable, también se toma en cuenta la funcionalidad de los métodos eléctricos de potencia y se denotan las principales causas de incertidumbre para la producción eléctrica en los paneles solares.

Debemos considerar que cada sub fase intervendrá en la malla eléctrica comercial y pasará a ser corriente alterna con ayuda de un inversor poder ser utilizada por las personas y es aquí donde recae su principio de energía de tipo renovable.

Por otro lado [4] con el aumento de la energía del sol, la producción de energía solar fotovoltaica (PV) está aumentando rápidamente en los distritos industriales, debido a que los sistemas fotovoltaicos dependen fundamentalmente del clima, cabe recalcar que pueden reducir la cantidad de energía consumida por la malla eléctrica.

La energía fotovoltaica tiene naturaleza intermitente lo que crea problemas al despachar esta energía en la malla eléctrica [4] debido a factores externos climáticos de una región, por lo que para su mejor estudio y producción se utilizan una serie de métodos y técnicas que ayudan a determinar la radiación solar.

2.2 Sistema fotovoltaico

También conocido como instalación de energía solar o instalación fotovoltaica es diseñada para generar energía eléctrica que se obtiene a través del sol. Cada sistema fotovoltaico está diseñado como una alternativa ecológica, limpia y eficiente.

Debido que la energía eléctrica es producida en base a un método fotovoltaico

se consideran variables como el número de horas de luz en el panel solar, los módulos que fueron puestos, la posición del sol, la radiación, la infraestructura y el potencial nominal.

Según [5], [6] manifiestan, los efectos fotovoltaicos son el principio por el cual una célula fotovoltaica transforma la energía solar en energía eléctrica. Con estos conceptos explicados anteriormente se puede decir que existen dos tipos de sistemas fotovoltaicos [6], los cuales son: el sistema fotovoltaico autónomo el cual está aislado de la red eléctrica, pero según [7] produce energía eléctrica para el consumo de cargas no conectadas a la red y modelos fotovoltaico enlazados a la malla eléctrica como se menciona en [8] las dos se muestran como opción en la producción de energía verde.

Una ventaja prometedora es que aprovecha la incidencia de la luz solar sobre el mismo sin ningún costo y ayuda al medio ambiente y a las personas, pero una desventaja significativas es su alto costo de construcción como lo menciona [5].

2.2.1 Partes del sistema fotovoltaico

En el sistema fotovoltaico encontramos componentes como el generador solar según [9], el generador o panel fotovoltaico, está conformado por células que captan los rayos solares y por el uso de un sistema fotoeléctrico se transforma en electricidad continua, la batería según [9] funciona como pila de energía, misma que se distribuye a los distintos componentes en caso que su producción sea mínima o no se tenga radiación, este refiere que es el punto donde se guarda la energía producida en el generador, el regulador de carga, es aquel que impide todas las descargas excesivas o sobrecargas lo que produce daños irreversibles, también [9] enfatiza que es un dispositivo electrónico que permite que las baterías dirijan la energía hacia otro destino

cuando estas estén cargadas y el inversor como dispositivo permite la transformar corriente continua en corriente alterna sin ningún problema [9].

3. Variables meteorológicas

3.1 Radiación solar

Es la potencia que se dispersa a todas direcciones como ondas electromagnéticas, tal como lo afirma [10]. Sin embargo los autores [11], [12] plantean que la radiación solar es la dispersión de la potencia proveniente del sol como ondas electromagnéticas en distinta frecuencia, tomando en cuenta la opinión del autor [11] existen cuatro tipos que son irradiación directa, difusa, reflejada e irradiación global que consiste en sumar las tres radiaciones.

3.2 Herramientas de predicción solar

Las herramientas que se utilizan para la predicción solar se dividen en aquellos que se utilizan para medir datos en tiempo real y las que se basan en modelos o métodos donde se introducen los datos para tener estimaciones [13].

3.3 Herramientas para medir datos en tiempo real

Se tiene las cámaras de cielo que se manipulan para localizar y determinar la altura de las nubes y después aplicar una serie de algoritmos que ayuden a establecer la futura posición de estas.

Las estaciones meteorológicas determinan los valores de manera instantánea de la velocidad de viento, la dirección de este y también valores de radiación sea esta global horizontal o radiación difusa horizontal para la cual se utilizan piranómetros, para la radiación directa normal se usan los pirheliómetros.

Los celiómetros son utilizados para decretar la altura de las nubes sobre todo en días claros en los cuales se aprecian nubes altas y muy finas que pasan desapercibidas por las cámaras de cielo.

El radiómetro es utilizado para establecer la concentración de aerosoles en la atmósfera que es esencial para la captación de la radiación en la superficie terrestre.

Las imágenes de satélite las usamos para establecer el tipo, la forma y la dirección de las nubes, y a partir de ello instaurar una cobertura nubosa. Con el uso del satélite también se puede determinar la cantidad de aerosoles contenida en la atmósfera.

3.4 Herramientas de métodos y modelos

Se puede utilizar dos métodos el numérico en el que introducimos las variables medidas con herramientas como es la velocidad y la dirección del viento, temperatura, presión entre otro y los métodos meteorológicos regionales que determinan características determinadas de una región como es la cantidad de polvo, niebla etc.

4. Metodología para el pronóstico de radiación solar

Para pronosticar la demanda eléctrica se consideran tres líneas de tiempo a corto, mediano y largo plazo y se basara en la probabilidad, con el objetivo de tener resultados lo más certeros posibles. Para ello es necesario identificar el problema y poder resolverlo de manera oportuna con los datos recopilados mediante la construcción de un modelo matemático que pueda validar los resultados a corto plazo es decir una predicción de horas, mediano plazo en días y largo plazo una predicción a meses [14].

La tendencia en este tipo de trabajos no aconseja que se trabaje con un predictor unitario más bien recomiendan que se use un predictor híbrido ya que son diseñados con dos o más predictores con atributos superiores lo que magnifica sus fortalezas individuales [15].

El pronóstico de generación solar a corto plazo nos da un enfoque indispensable que tiene beneficios para la unidad de compromiso el control de generación y la comercialización de energía [16], ya que conforme pasa a la red cada operador u operadores de transmisión se benefician con la programación y control del área de equilibrio para medio y largo plazo solar pronosticar la previsión de energía.

4.1 Sistema de variables a corto plazo

La Generación Fotovoltaica (PV) cuando es menor al 10% de la generación total, no es importante el pronóstico a corto plazo, sin embargo, cuando supera dicho umbral, es necesario pronosticar la contribución de este tipo de generación para que se pueda operar correctamente el sistema [3]. Es por ello que es necesario comenzar a investigar esta temática pues servirá para un futuro desarrollo de modelos de pronóstico de la operación a diario.

En el sistema de intervalos de horas, se tiene variables entre ellas destacan los problemas naturales que se ven afectados por factores como las condiciones meteorológicas y en cierto modo factores económicos que pueden afectarlo de diversas formas.

Siendo así, si se reduce el horizonte de predicción se puede disponer hablar de errores de predicción ya que se utiliza este periodo de predicción para poder interactuar en el mercado eléctrico de manera diaria, tomando en cuenta cada país. Para el caso de la predicción de la

potencia eléctrica producida en un panel solar fotovoltaico no existe unanimidad en cuanto cuales son las fronteras que separan, es más, la mayoría de los autores que se relacionan con este tema evitan cuantificar los términos y aquellos que lo hacen dan valores diferentes, en especial para la predicción a muy corto plazo [17], [18].

4.2 Sistema de variables a mediano plazo

El pronóstico a mediano plazo es importante ya que nos ayuda a planificar el mantenimiento en las instalaciones y ver el consumo de combustibles requeridos para suministrar energía eléctrica en periodos que comprenden hasta días [19]. Este pronóstico aparte de ser influenciado por los factores climáticos es también afectado por las condiciones socioeconómicas ya que estas influyen en el pronóstico de la demanda energética mensual.

En este sistema tomamos en cuenta el histórico de datos de consumo de energía, ya que este se muestra como un efecto cíclico donde su pico va a cambiar en un periodo de tiempo, pero también debemos considerar el aumento poblacional y el incremento de uso de energía.

4.3 Sistema de variables a largo plazo

Conocido como máximos anuales es imprescindible para la planeación de nuevas estaciones energéticas y líneas de transmisión, también en el cálculo del uso de combustibles y los valores de producción de potencia eléctrica, por eso este pronóstico es para meses [19]. Por lo tanto para [17], cuanto mayor sea el horizonte mayores serán los errores de predicción ya que estos tendrán mayores variables socioeconómicas tomando en cuenta el crecimiento poblacional, el PIB, la variación climática y meteorológica por lo que estas predicciones son de interés para

analizar la construcción de nuevas centrales convencionales y planificar programas de mantenimiento de las centrales [19].

5. Redes neuronales artificiales

Radica el interés en su capacidad para discernir datos complejos de forma eficiente y mediante un algoritmo y entrenamiento buscan la relación entre patrones de datos complejos para ser expresados de manera simple.

Las RNAs son modelos de resolución de problemas de forma individual o colectiva a otros modelos para la clasificación optimización o predicción en el balance de datos de conocimiento que se inclinen a datos de incertidumbre en donde existe la necesidad de aprendizaje en tiempo real y la tolerancia a errores. Para estos casos las RNAs se ajustan de forma simultanea ajustando los pesos de sus interrelaciones [20]. Por lo tanto, la RNAs son procesadores elementales conformados por neuronas con una limitada capacidad que analiza y sintetiza una gran cantidad de datos para luego pasar a la siguiente neurona como una señal. Las RNAs están diseñadas en capas o niveles que se interrelacionan entre sí con un peso específico a través del algoritmo de aprendizaje que puede ser supervisado o no, cada RNA se adapta a su diseño y parámetros de forma que reduzcan las características de error y muestren un elevado nivel en el cierre de datos y capacidad de difundirlo a las demás RNAs.

5.1 Características de redes neuronales artificiales

Las RNAs están conceptualizadas a partir de las RN Biológicas por esta razón tienen un parecido al cerebro humano [21]. Esta semejanza da características hace que al igual que nosotros estas redes aprendan de la experiencia y puedan generalizar de los ejemplos previos a ejemplos nuevos.

Pero ello deriva varios aspectos como el aprender donde cada persona adquiere conocimiento de un tema mediante mecanismos como el ejercicio o la experiencia, mientras que las RNA pueden aprender mediante la experiencia que tiene de su entorno, por lo que se manifiestan varias entradas y estas a su vez generas salidas sólidas. Aprender a universalizar un tema que se desea ampliar o detallar para mejorar la comprensión, por el contrario, las RNAs se extienden por ellas mismas gracias a su ajustada estructura y naturaleza, por lo que estas pueden brindar un porcentaje con respuestas acertadas a las entradas donde se visualizan mínimas diferencias gracias a los factores de ruido o distorsión. La abstracción consiste en separar ciertas cualidades que destacan de un objeto, pero algunas RNAs son idóneas para aislar el atributo en un grupo de ingresos que por simple vista no tienen semblantes comunes o relativos.

5.2 Estructura básica de una red neuronal

Denotando la similitud con el cerebro humano una neurona artificial seria la unidad de procesamiento de datos que recibe y combina señales para el resto de neuronas y si la interrelación de datos es alta la salida de los resultados será activa [21].

5.3 Tipos de capas

5.3.1 Capa unicapa

Se pretende no contar la capa de entrada por ello se dice que la malla que se observa en la figura 3 se denominara unicapa, por lo tanto, la síntesis esta ordenada en matrices y por ello la red unicapa solo puede resolver problemas linealmente separables ya que en este tipo de capas las neuronas pueden o no ser lineales.

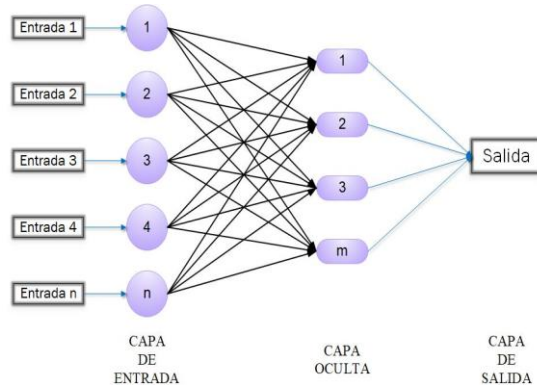


Figura 1. Esquema Unicapa.

5.3.1.1 Entrenamiento y aprendizaje de capa neuronal unicapa

El objetivo y funcionamiento general de aprendizaje es diseñado especialmente para el reconocimiento de patrones, pero como es una red unicapa, sólo se pueden usar patrones lineales que sean separables [22].

5.3.2 Capa multicapa

Con mención a la capa unicapa también se puede involucrar más capas a esto se lo llamara Multicapa que siempre son no lineales, son de fácil constitución para una red multicapa con capas ocultas lineales que equivalen a una red unicapa.




Figura 2. Esquema Multicapa.

Se puede ver la idea de paralelismo puesto que cada neurona de una capa no necesita de más capas para trabajar ya que son capaces de realizarlo simultáneamente. Por lo tanto, una red multicapa es capaz de ayudar a resolver problemas complejos pero su procesamiento y aprendizaje es de difícil aplicación.

5.3.2.1 Aprendizaje y entrenamiento de capas neuronales multicapas

En esta clase de redes, las activaciones de las capas ocultas son no lineales y observamos que las ecuaciones que necesita para la función de activación es única en todo el dominio y se encuentra que este algoritmo de aprendizaje es más complejo de visualizar. Nosotros sólo estudiaremos el Aprendizaje Retro- propagador de Error [22].

6. Programación y entrenamiento de redes neuronales artificiales

Los métodos habituales de programación que se usa para resolver un conflicto necesita de la creación de un algoritmo que es una secuencia de órdenes para que proceda el sistema en base a su ordenador para lograr el fin que es la solución del problema.[21]. Los algoritmos para ser utilizados deben ser programadas y

entrenadas previamente por ello a la malla se le va a mostrar en una capa de ingreso.

6.1 Arquitectura

Las RNA tienen una arquitectura distinta a los ordenadores convencionales de un solo procesador. Esto quiere decir que los comandos que se ejecutaran son secuenciales y sincronizados al reloj interno del sistema y se toma en cuenta que cada elemento solo realiza uno o varios cálculos, por lo tanto, para el proceso de las RNAs se va a medir inicialmente en base al número de conexiones que se debe actualizar cada segundo mientras dure el periodo de entrenamiento de la misma.

La arquitectura de las RNA inicia en la clasificación del sistema procesador en paralelo esto quiere decir que los procesadores se encuentran interconectados, aunque cada procesador en una unidad independiente creada para la suma de varias entradas y un ajuste autónomo de las conexiones ponderadas [21].

6.2 Sistemas expertos

Esta técnica se utiliza específicamente para que no exista una persona con conocimientos en el área en donde se pueda crear reglas que puedan codificar el conocimiento, por lo tanto, estos sistemas expertos se diferencian de la programación tradicional en el conocimiento.

Para la creación de una RNA no debemos disponer el conocimiento ni las leyes de su procesamiento.

La red neuronal asimila las leyes para procesar el conocimiento basándose en simulaciones de sus conexiones ponderadas entre neuronas de diferentes capas de la malla. [21].

7. Implementación de los algoritmos y simulación en matlab

7.1 Pronóstico de radiación solar

Para el caso de la metodología se utilizaron tres tipos de algoritmos en los cuales se enfocan, cada uno a la red neuronal multicapa por lo cual tienen las mismas entradas que vienen a ser ocho (Día, Mes, Hora, Temperatura, Humedad relativa, Precipitación, Velocidad del viento, Dirección del viento) con una capa oculta.

Cada una de las variables se obtuvieron por medio de la estación meteorológica las cuales fueron tomadas durante el año 2020 obteniendo así 17,472 datos de cada una de las variables las cuales van a ser utilizadas el 70% en el entrenamiento, 15% para validación y el 15% sobrante para pruebas.

Los tipos de algoritmos que se utilizaron para las pruebas fueron el algoritmo de Levenberg-Marquardt o método de mínimos cuadrados amortiguados no lineales, por esta razón se indica que los problemas surgen al ajustar las curvas de los mínimos cuadrados, el algoritmo de Regularización Bayesiana, es un proceso en el cual se agrega información de tal modo que se pueda resolver un problema que se encuentra mal planteado y que a su vez este sirva para prevenir un sobreajuste y por último el algoritmo de Gradiente de Escala Conjugada que es un algoritmo de aprendizaje reiterado el que permite resolver redes neuronales artificiales que sean relevantes por su velocidad de correlación frente a la propagación hacia atrás de errores. Esto se debe a que utiliza derivadas de segundo orden, lo que permite una coincidencia más veloz.

Cuando se corrió los diferentes algoritmos obtuvimos las siguientes tablas comparativas.

Tabla 1. Resultados de los datos de validación Levenberg-Marquardt.

	Muestras	MSE	R
Entrenamiento	12230	4954,124e-0	9,633e-1
Validación	2621	4918,264e-0	9,630e-1
Prueba	2621	5284,188e-0	9,612e-1

Tabla 2. Resultados de los datos de validación de Regularización Bayesiana.

	Muestras	MSE	R
Entrenamiento	12230	4829,459e-0	9,646e-1
Validación	2621	0,0000e-0	0,000e-1
Prueba	2621	4865,756e-0	9,614e-1

Tabla 3. Resultados de los datos de Gradiente de Escala Conjugada.

	Muestras	MSE	R
Entrenamiento	12230	5790,544e-0	9,570e-1
Validación	2621	5949,451e-0	9,555e-1
Prueba	2621	5631,115e-0	9,578e-1

En las 3 tablas se observa el número de muestras que fueron entrenadas, validadas y las que se realizó pruebas, en la tercera columna indica el Error medio cuadrático MSE, y la correlación de los datos R, para evaluar el algoritmo que se ajusta mejor, se ha considerado el que tenga un MSE más cercano a cero, y una correlación R cercana a uno.

Por lo tanto, para la creación de la red neuronal artificial multicapa se recomienda el algoritmo de Regularización Bayesiana ya que esta nos llevó a una cantidad pequeña de error el cual se puede notar en las consecuencias de los simulacros, puesto que los valores logrados del pronóstico de radiación solar son similares a los valores de los datos obtenidos por parte de la estación meteorológica.

7.2 Creación de un módulo fotovoltaico en Matlab/Simulink

En la creación de un módulo fotovoltaico, hay que tener en cuenta que este necesita toma de datos meteorológicos

tales como son la radiación solar y la temperatura para la creación del módulo fotovoltaico se ha decidido por el modelo de diodo único con resistencias en serie y paralelo ya que este nos ofrece una mayor precisión, para las salidas de este modelo realizado podemos obtener entre corriente, voltaje, potencia entre otros.

Para este trabajo se ha tomado en cuenta la salida de potencia voltaje ya que se va a pronosticar a partir de una radiación solar dada en un instante de tiempo cuanta cantidad de potencia este puede entregar, sino también que este valor sea el más cercano a la realidad.

Los parámetros vienen dados en la ficha técnica del fabricante tal como se puede ver en la siguiente tabla 4 los cuales nos permitirán realizar la simulación.

Tabla 4. Datos proporcionados por el fabricante.

Datos	MSE
Imp	4,4 A
Vmp	17 V
Isc	6.11 A
Voc	21.6 V
Rs	0.55 Ω
Rp	1000 Ω
Usc	$1.3 * 10^{-3}$
Número de células en serie NS	36 de 5
Número de células en paralelo NP	1

La siguiente grafica representa el circuito del módulo fotovoltaico a utilizar con la resistencia en serie y paralelo.




Figura 3. Circuito fotovoltaico con resistencia serie y paralelo.

Las siguientes ecuaciones son utilizadas para el proceso de simulación de un módulo fotovoltaico.

$$I = I_{ph} - I_d - I_p \quad (1)$$

Donde:

I_{ph} : Fotocorriente.

I_d : Corriente del diodo.

I_p : Corriente resistencia.

La ecuación (1) se obtiene a partir de la corriente de salida por la ley de Kirchhoff.

Es absurdo despreciar la resistencia en serie y paralelo, ya que estos nos permiten tener una mayor eficiencia en el módulo fotovoltaico y su celda, para lo cual la ecuación (2) nos permitirá obtener nuestra corriente de diodo tomando en cuenta nuestra R_S .

$$I_d = I_0 \left[\exp\left(\frac{V + I * R_S}{a}\right) - 1 \right] \quad (2)$$

Donde:

I_0 : Corriente de fuga del diodo.

V: voltaje impuesto sobre el diodo.

a: Factor de idealidad modificado.

$$a = \frac{N_S * A * k * T_C}{q} \quad (3)$$

Donde:

N_S : Número de células en serie.

A: Factor de idealidad.

k: Constante de Boltzmann
1.381 x 10⁻²³ J/K

q: Constante de la carga de electrones
1.381 x 10⁻¹⁹ C.

T_C : Temperatura real de la celda (°K).

El valor del factor de idealidad (A), se obtuvo mediante la tecnología con la cual se va a trabajar en este caso al ser a-Si-H su valor es de 1.8.

Para determinar I_{ph} esta depende de la radiación solar como también de la temperatura.

$$I_{ph} = \frac{G}{G_{ref}} (I_{ph,ref} + u_{sc} * \Delta T) \quad (4)$$

Donde:

G: Radiación solar w/m².

G_{ref} : Radiación solar en STC 1000w/m²

u_{sc} : Coeficiente de temperatura de corriente de cortocircuito, proporcionada por el fabricante.

$I_{ph,ref}$: Fotocorriente en STC.

ΔT : Variación de temperatura de la célula (°K).

$$\Delta T = T_c - T_{c,ref} \quad (5)$$

Para este análisis se consideró la realización del módulo fotovoltaico como corriente de cortocircuito y voltaje de circuito abierto para determinar el lugar imponderable de energía.

Se determina I_0 esto a partir de algunos parámetros proporcionados por los fabricantes y otros relacionados con la tecnología de la celda fotovoltaica como lo es ϵ_G , las variables a y T_c dependen de la temperatura real esto por el motivo que I_0 tiene que ser determinado en tiempo real.

$$I_0 = I_{sc,ref} \exp\left(\frac{-V_{oc,ref}}{a}\right) \left(\frac{T_c}{T_{c,ref}}\right)^3 \times \exp\left[\left(\frac{q\epsilon_G}{A * k}\right) \left(\frac{1}{T_{c,ref}} - \frac{1}{T_c}\right)\right] \quad (6)$$

Donde:

ϵ_G : Constante de energía de banda prohibida de material 1.12eV.

Todos los valores referenciales hacen parte de los valores estándar de las pruebas.

Para un valor explícito de corriente fotovoltaica o corriente cedida por la celda y la tensión eléctrica, obtendremos un punto

en el cual la energía cedida a una carga será máxima conocida, así como puesto de máxima energía, la figura 4 representa el máximo puesto de energía.

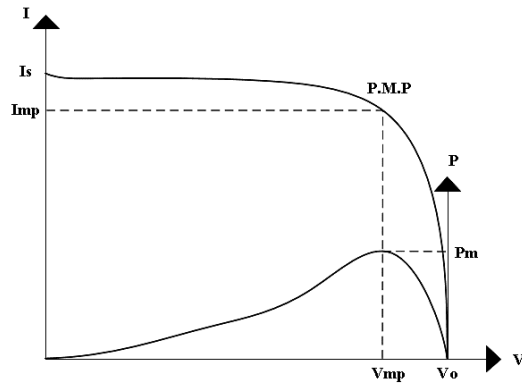


Figura 4. Punto de Máxima Potencia.

Donde:

P_m : Valor máximo de potencia que puede entregar el dispositivo.

I_{mp} : Corriente a la máxima potencia

V_{mp} : Tensión a la máxima potencia.

$V_o = V_{oc}$: Tensión de cortocircuito.

$I_s = I_{sc}$: Corriente de cortocircuito.

Para determinar la máxima energía cedida por el módulo fotovoltaico se expresa la siguiente ecuación.

$$P = I * V \quad (7)$$

Donde:

P : Potencia máxima entregada por el módulo fotovoltaico.

I : Corriente de salida del circuito fotovoltaico.

V : Voltaje de salida del circuito fotovoltaico.

Entonces podemos decir que nuestras entradas en el módulo fotovoltaico van a ser radiación solar, temperatura, I_{mp} , V_{mp} , I_{sc} , V_{oc} , R_s , R_p , U_{sc} y N_s las cuales nos van a permitir simular nuestro punto de potencia máximo para lo cual se calculan las corrientes I_{ph} y I_o , de esta manera

vamos a poder obtener nuestro punto de máxima potencia.

Las ecuaciones mencionadas por el autor [23], permitieron llegar a la solución de un modelo fotovoltaico.

8. Análisis de resultados

En inteligencia artificial la técnica de RNA permite la predicción en un periodo de tiempo ya sea largo, medio o corto, dando un resultado aproximado a lo que se podría tener en la realidad, en este caso la técnica utilizada es una red neuronal artificial la cual dispone de 8 entradas misma que nos da un resultado muy cercano a la realidad en cuanto se hace una predicción de radiación solar en un periodo de tiempo de días, semanas y meses, ya que al realizarlo en un periodo corto de tiempo como lo puede ser en horas la red neuronal al no tener suficientes datos no realiza una buena predicción ya que nuestros datos los obtuvimos de una estación meteorológica que considera las cuatro estaciones.

Tabla 5. Fechas de las estaciones meteorológicas.

Estaciones	Periodo
Primavera	Comienza el 20 de marzo y termina el 21 de junio.
Verano	Comienza el 21 de junio y termina el 22 de septiembre.
Otoño	Comienza el 22 de septiembre y termina el 21 de diciembre.
Invierno	Comienza el 21 de diciembre y termina el 20 de marzo

Por lo tanto, existen fechas en las que la radiación solar llega hasta las 20:30 y otras fechas llega hasta las 17:30, y esto hace que la red neuronal artificial tienda a tener un mayor error. Para demostrar este error se ha considerado realizar el análisis en diferentes periodos de tiempo de donde se obtuvieron diferentes datos.

8.1 Análisis trimestral

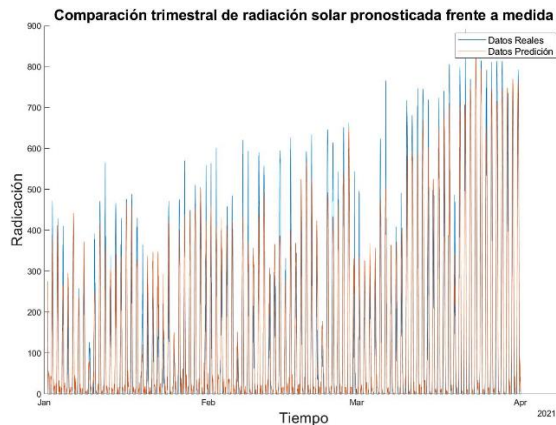


Figura 5. Radiación medida frente a pronosticada de enero 1 a marzo 31.

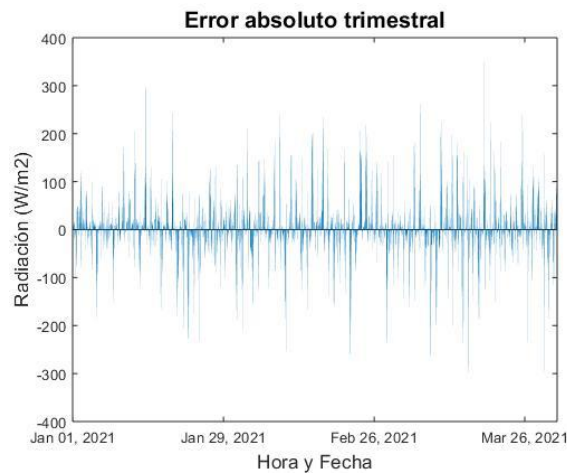


Figura 6. Error absoluto de enero 1 a marzo 31.

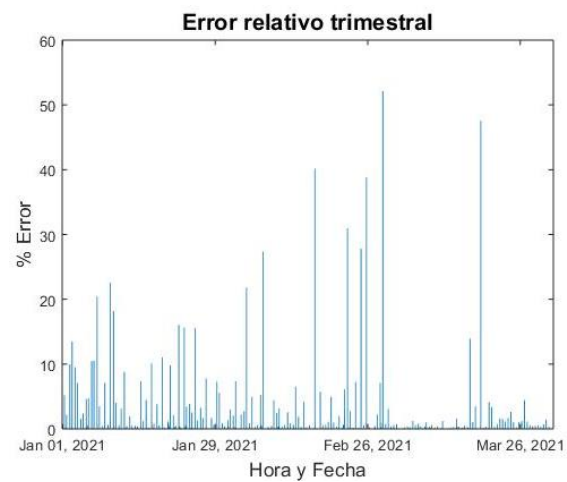


Figura 7. Error relativo de enero 1 a marzo 31.

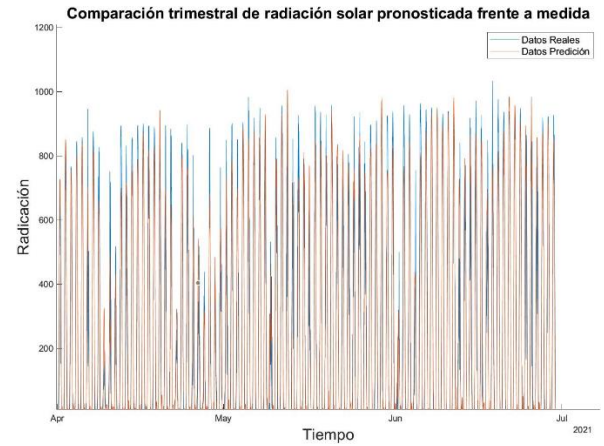


Figura 8. Radiación medida frente a pronosticada de abril 1 a junio 31.




Figura 9. Error absoluto de abril 1 a junio 31.




Figura 10. Error relativo de abril 1 a junio 31.

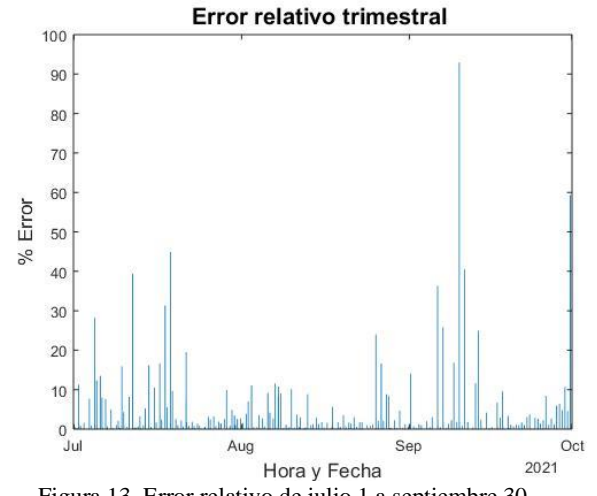


Figura 13. Error relativo de julio 1 a septiembre 30.




Figura 11. Radiación medida frente a pronosticada de julio 1 a septiembre 30.

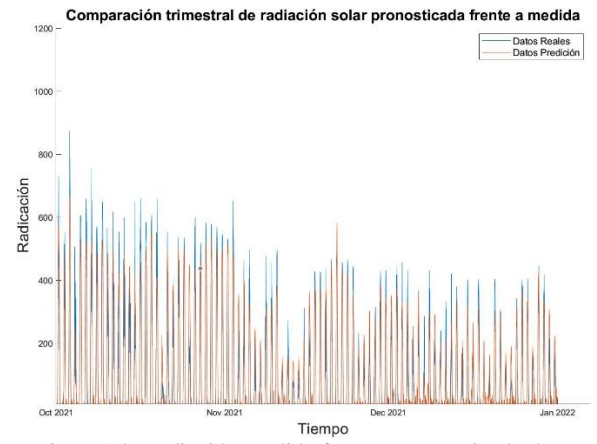


Figura 14. Radiación medida frente a pronosticada de octubre 1 a diciembre 31.




Figura 12. Error absoluto de julio 1 a septiembre 30.




Figura 15. Error absoluto octubre 1 a diciembre 31.

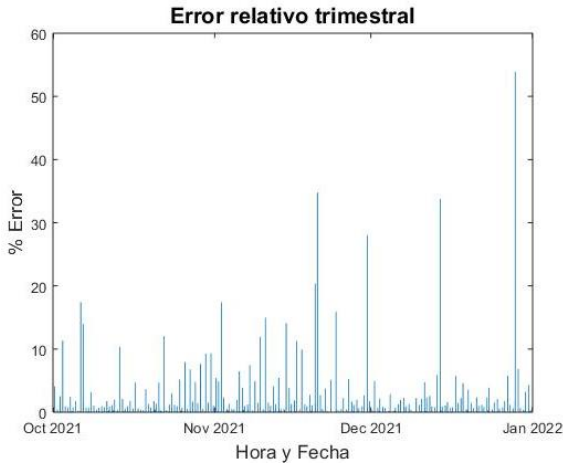


Figura 16. Error relativo octubre 1 a diciembre 31.

Para un caso de estudio realizado en forma trimestral donde se pueden observar en las figuras 5, 8, 11 y 14, sucede que el entrenamiento es cercano a la realidad, pero se puede visualizar que existe un error, esto depende del adiestramiento de la malla neuronal y la cantidad de datos ingresados a la misma sabiendo que entre mayor cantidad de datos se disponga mayor será su pronóstico a la realidad. Mientras que en las gráficas 6, 9, 12 y 15 se puede denotar que existe el error en formato de radiación es decir en w/m^2 en donde se puede visualizar la cantidad de error que se dispone para esas graficas tomadas.

En el caso de las gráficas 7, 10, 13 y 16 se observa el porcentaje de error que se dispone y se puede decir que el error relativo de cada grafica ubica unos picos, estos picos me representan que en tales días existió una variación de factores climáticos los cuales fueron diferentes a los datos reales y esto hace que me resalte un error relativo en forma pronunciada esto se basa porque para pronóstico de radiación solar intervienen los factores climáticos los cuales no siempre se mantienen constantes es por eso que se dispone de picos.

8.2 Análisis mensual

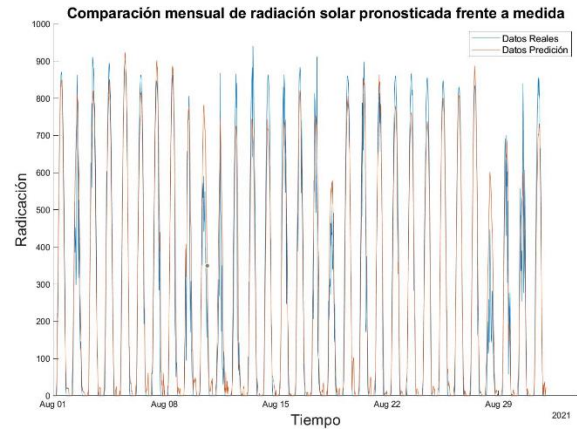


Figura 17. Radiación medida frente a pronosticada del mes de agosto.

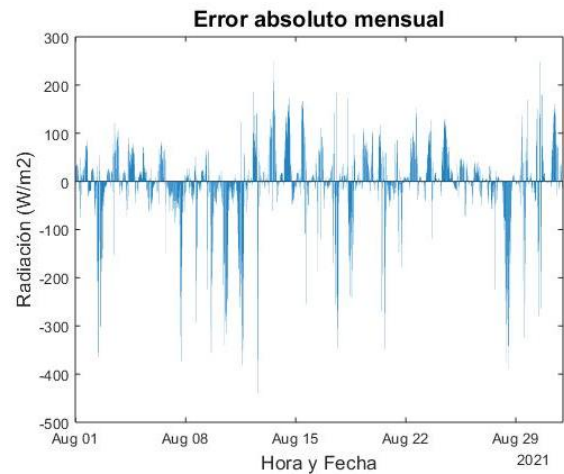


Figura 18. Error mensual del mes de agosto.

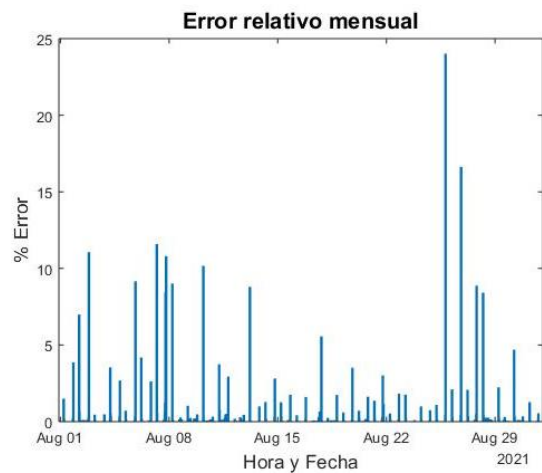


Figura 19. Error relativo del mes de agosto.

En la figura 17 se evidencia que el pronóstico de radiación solar para el mes de

agosto se obtiene una buena predicción, esto depende por la temporada ya que agosto se encuentra en verano por lo tanto se tienen altos niveles de radiación solar, pero en la figura 18 representa al tener una buena predicción también existe un error a lo largo del tiempo del mes de agosto esto sucede por el adiestramiento de la malla neuronal, en la figura 19 se observa que se dispone de un pico pronunciado en el error relativo y esto se hace porque en ese día afectaron factores climáticos los cuales fueron diferentes a los datos originales y hace que se distinga una punta pronunciada en el pronóstico.

8.3 Análisis diario

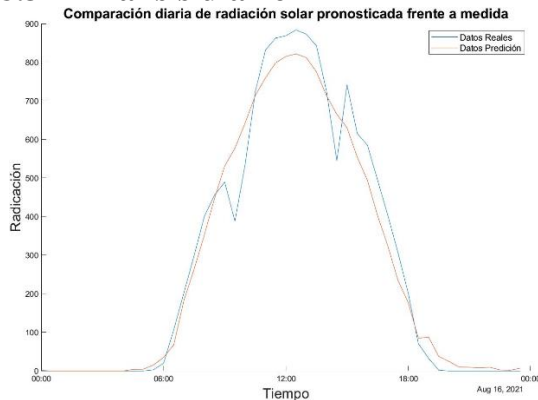


Figura 20. Radiación medida frente a pronosticada mes de agosto 16 de 00:00 a 23:30.

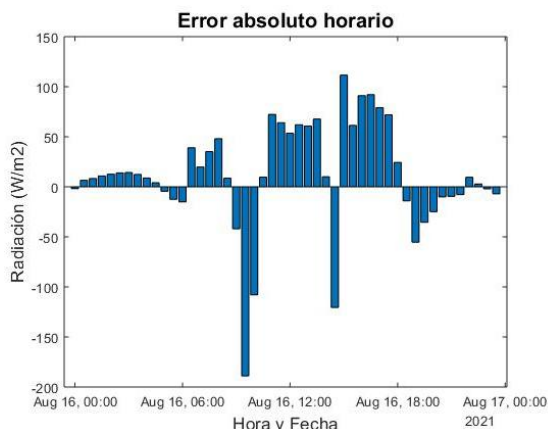


Figura 21. Error diario del mes de agosto día 16 de 00:00 a 23:30.

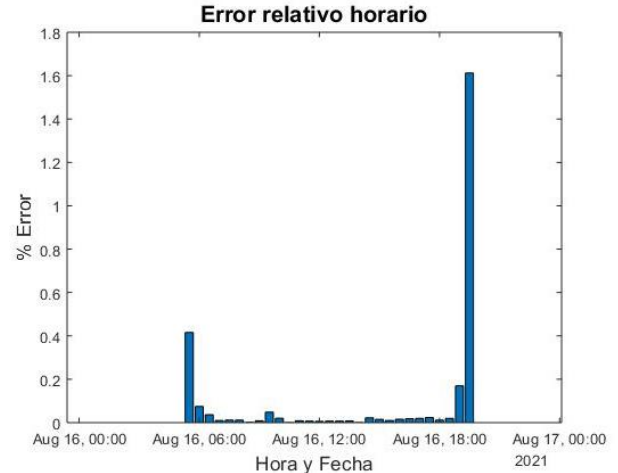


Figura 22. agosto día 16 de 00:00 a 23:30.

Al tener una correlación en la figura 20 se puede ver que los datos reales sobrepasan a los valores pronosticados y también se puede denotar que la predicción de radiación solar en partes llega a ir de la mano con los datos originales para ese día la radiación solar pronosticada en ese día es a las 5:30am mientras que el de predicción manda un dato de radiación solar a las 4:30am pero en si cuando va a comenzar su pico de ascenso comienza a las 5:00am; al llegar a su pico máximo que viene ser a las 12:30 la radiación solar es de $884 w/m^2$ en valores reales, el pico máximo que llega a tener el pronóstico de radiación solar es de $821w/m^2$ es decir existe un mínimo error pero esto se puede dar por todo el adiestramiento de la malla neuronal artificial por que en total la red neuronal fue entrenada con 17473 datos.

Para el día 16 de agosto se puede notar la tendencia que existe del error horario en la figura 21 y tenemos un pico de error de $-189 w/m^2$ a la hora de 9:30am esto es porque ese día en los datos reales existió un decaimiento de radiación solar que pudo a ver sucedido por la obstrucción de radiación solar por alguna nube y de igual manera se puede verificar la existencia de otro pico de $111.6 w/m^2$ a las 15:00pm donde se podría decir que se despejó por un momento el sol y pudo captar mayor

radiación solar en ese instante del día y por ultimo analizamos la figura 22 donde vemos que el error relativo no sobrepasa el 2% lo que nos asegura que nuestro entrenamiento fue exitoso y los datos obtenidos tienen relación con los valores reales.

Tabla 6. Valores de datos reales frente a pronosticado.

Hora	Radiación global	Radiación global pronosticada
4:00	0	0
4:30	0	4,063
5:00	0	4,411
5:30	3	15,48
6:00	20,1	35,14
6:30	106,8	67,78
7:00	203,1	183,3
7:30	299,3	264,1
8:00	400,7	352,6
8:30	456	447,7
9:00	489,5	531,5
9:30	388,4	577,4
10:00	534,5	642,6
10:30	724	714,3
11:00	832	759,9
11:30	863	798,9
12:00	869	815,4
12:30	884	821,9
13:00	873	812,3
13:30	843	775,3
14:00	723	713
14:30	545	665,5
15:00	742	630,4
15:30	615,7	554,4
16:00	585,3	494,3
16:30	494,6	402,5
17:00	403,4	324,3
17:30	306,7	234,8
18:00	201,7	177,4
18:30	71	85,08
19:00	32,6	88,01

Como se puede observar en la tabla 6 la relación que existe entre los valores de la estación meteorológica y los valores obtenidos en el pronóstico de radiación

solar se observa que existe una buena relación tomando en cuenta que los datos fueron tomados cada media hora y sabiendo que entre menor sea el plazo en la toma muestras mayor exactitud se obtendrá.

Al realizar una comparación con los artículos [1], [2] que sirvió como guía en la creación de la RNA donde se puede comparar el tipo de algoritmo de entrenamiento utilizado, se puede decir que nuestro método es más eficiente ya que las variables utilizadas en este artículo son más lo cual reduce el índice de error tomando en cuenta que los valores para el entrenamiento de la red neuronal fueron tomados cada 30 minutos.

8.4 Simulación de un módulo fotovoltaico completo

Para la simulación de un módulo fotovoltaico se realiza la predicción de potencia a partir de la predicción de la radiación solar de la imagen 20 y tomando en cuenta los valores obtenidos de la tabla (6).

Las curvas presentadas son del día 16 de agosto a las siguientes horas 6:30, 8:00, 9:30, 11:00, 12:30, 14:00, 15:30, 17:00 y 18:30, donde se va a poder observar que a diferente radiación pronosticada a esas horas vamos a obtener diferente valor de potencia a lo largo de ese tiempo.




Figura 23. Pronostico de potencia a las 6:30.




Figura 27. Pronostico de potencia a las 12:30.




Figura 24. Pronostico de potencia a las 8:00.




Figura 28. Pronostico de potencia a las 14:00.




Figura 25. Pronostico de potencia a las 9:30.




Figura 29. Pronostico de potencia a las 15:30.




Figura 26. Pronostico de potencia a las 11:00.




Figura 30. Pronostico de potencia a las 17:00.




Figura 31. Pronostico de potencia a las 18:30.

Presentando las gráficas del pronóstico de potencia podemos observar que a cada valor de pronóstico de radiación solar obtenido tenemos diferentes valores de potencia esto sucede por el total de irradiación solar captada el modulo fotovoltaico el cual al obtener diferentes valores de radiación solar va entregando diferentes valores de potencia.

Para los valores de potencia se realizó con una temperatura de operación de 25°C, en la siguiente tabla presentada se puede observar que a diferente valor de radiación solar de valor real y el pronosticado se va obteniendo los valores de potencia diferentes, esto como se menciona es por la variación de radiación solar.

Tabla 7. Valores obtenidos de potencia de pronóstico de valores reales y pronóstico de valores de radiación solar.

Hora	6:30	8:00	9:30	11:00
Potencia pronosticada de valores real (W)	9,80	40,20	38,89	87,44
Potencia pronosticada de valores pronosticados (W)	6,02	35,08	59,30	79,39

Hora	12:30	14:00	15:30	17:00
Potencia pronosticada de valores real (W)	93,26	75,32	63,49	40,49
Potencia pronosticada de valores pronosticados (W)	86,31	74,21	56,79	32,02

Hora	18:30
Potencia pronosticada de valores real (W)	6,33
Potencia pronosticada de valores pronosticados (W)	7,68

En la comparación del máximo punto de potencia realizado en simulink nos fuimos guiando a partir del siguiente trabajo [24] el cual nos permitió revisar y analizar los diferentes casos que puede optar a partir de un cambio de radiación solar, en el trabajo realizado se puede verificar que a partir de un dato de radiación solar en un instante de tiempo podemos obtener un valor aproximado de la potencia que puede entregar este en ese momento este podría ser mayor o menor de acuerdo a la radiación captada por el modulo fotovoltaico.

9. Conclusión

El presente trabajo realiza el pronóstico de radiación solar de una estación meteorológica basado en un modelo de red neuronal artificial multicapa, para ello se utilizó el algoritmo de regularización Bayesiana, los resultados mostrados son muy aceptables ya que tienen un gran desempeño en la red neuronal en cuanto a la estimación de radiación solar, pero con base a que se puede perfeccionar y minimizar la cantidad de error disponible para ello se debe trabajar con una mayor

cantidad de datos de preferencia de los últimos 4 años, esto para que la red tenga un mayor aprendizaje en cuanto a la estimación de radiación solar tomando en cuenta de igual manera su entrenamiento por meses esto por la estación meteorológica que dispone de las 4 estaciones y al realizar el entrenamiento por partes no se verán mezclados los datos de primavera, verano, otoño e invierno esto con la finalidad de llegar al resultado exacto de la estimación de radiación solar.

El desarrollo y estudio llevo a acabo a la creación de un modelo el cual puede ser utilizado para predecir la energía que este puede entregar conociendo los valores de radiación solar y temperatura estos valores pueden ser anuales, mensuales o diarios, la finalidad es analizar el resultado de energía que a mayor radiación solar a una misma temperatura aumenta su potencia, pero en el caso de variar su radiación solar y su temperatura las variables de corriente, voltaje y potencia van a variar ya que estos son directamente proporcionales a la obtención de la energía.

9.1 Trabajos futuros

Los resultados mostrados en este artículo, pueden servir de guía de futuras investigaciones con relación al pronóstico de radiación solar para plantas fotovoltaicas en Ecuador, para el cálculo de la predicción de potencia que se obtendrá en los meses de mayor incidencia de radiación solar en el año tomando en cuenta que se recomienda una base de datos mínima de 4 años atrás para la generación de superiores resultados ya que como vimos en este trabajo mientras más datos existe menor índice de error se obtendrá.

10. Referencias

- [1] D. M. Morales, M. Cappelletti, W. Hasperu , and L. Charlier, “Entrenamiento de una red neuronal artificial para la predicci n de la radiaci n solar,” pp. 405–412.
- [2] V. A. Jimenez, A. Will, and S. Rodr guez, “Estimaci n de radiaci n solar horaria utilizando modelos emp ricos y redes neuronales artificiales,” *Cienc. y Tecnol.*, vol. 1, no. 17, p. 29, 2017.
- [3] M. A. G. Rodr guez, J. R. G. Sarduy, J. V. L. Ginori, R. F. Gonz lez, and Z. G. S nchez, “Pron stico de la generaci n el ctrica de sistemas fotovoltaicos. Un inicio en cuba desde la universidad,” pp. 253–265, 2021.
- [4] C. H. Dagli *et al.*, “Pron stico de la producci n de energ a de un sistema fotovoltaico solar utilizando t cnicas de inteligencia artificial y transformaci n de ondas,” vol. 12, pp. 332–337, 2012.
- [5] D. Barber  Santos, “Introducci n a la energ a fotovoltaica,” pp. 1–20, 2017.
- [6] M. Alonso, “Master en energ as renovables y mercado energ tico,” *Ciemat*, vol. 1, no. 1, p. 59, 2011.
- [7] O. P. Lamigueiro, “Sistemas fotovoltaicos aut nomos conceptos generales y componentes,” 2017.
- [8] M. C ceres, A. Busso, L. Vera, A. Firman, G. Leiva, and L. Luque, “Sistemas fotovoltaicos conectados a red: estabilidad en los par metros de la red y sus efectos en la capacidad de generaci n,” *Rev. Bras. Energ. Sol.*, vol. 4, no. 1, pp. 47–54, 2013.
- [9] F. D. V lez Mosquera and C. X. Grijalva Campoverde, “Estudio e implementaci n de un sistema fotovoltaico aplicado a luminarias: caso de estudio Unidad educativa Dr. Francisco Falqu z Ampuero,” *Repos. Inst. la Univ. Polit cnica Sales.*, vol. 0, no. 0, 2020.
- [10] N. A. Carrasco Catal n, I. A. Calle, A. C rdenas Angulo, and E. Soto Sep lveda, “Predicci n de potencia a corto plazo para plantas fotovoltaicas utilizando redes neuronales artificiales,” 2017.
- [11] J. E. Cata S nchez, F. M. Rodr guez S cola, and R. S. Jara Msing, “An lisis matem tico de un panel solar fotovoltaico de silicio,” 2015.
- [12] F. R. Paler, “Predicci n mediante redes neuronales de la producci n de energ a de un parque fotovoltaico,” 2017.
- [13] I. Z. Ducun, “Predicci n de radiaci n solar a corto y medio plazo,” 2014.
- [14] Y. J. Reddy, Y. V. P. Kumar, V. S. Kumar, and K. P. Raju, “Distributed anns in a layered architecture for energy management and maintenance scheduling of renewable energy HPS microgrids,” no. 1, 2012.

- [15] E. D. Obando Paredes, “Modelo de pronóstico de radiación solar basado en Machine Learning,” 2018.
- [16] R. K. Sahu, B. Shaw, and J. R. Nayak, “Short / medium term solar power forecasting of chhattisgarh state of india using modified TLBO optimized ELM,” *Eng. Sci. Technol. an Int. J.*, no. xxxx, 2021.
- [17] A. M. Jiménez, “Modelos de predicción a corto plazo de la generación eléctrica en instalaciones fotovoltaicas,” 2014.
- [18] M. Abuella and B. Chowdhury, “Solar power forecasting using artificial neural networks,” no. November, 2015.
- [19] D. I. Cabrera Calopiña, *Diseño de una red neuronal artificial para la predicción de la demanda eléctrica*. 2014.
- [20] M. Ramón Mantilla, “Redes neuronales artificiales.”
- [21] X. Basogain Olabe, “Redes neuronales artificiales y sus aplicaciones,” 2016.
- [22] F. Izaurieta and C. Saavedra, “Redes neuronales artificiales,” 2018.
- [23] H. Bellia, R. Youcef, and M. Fatima, “Modelado detallado de un módulo fotovoltaico utilizando matlab,” *NRIAG J. Astron. Geophys.*, vol. 3, no. 1, pp. 53–61, 2014.
- [24] F. Ibáñez Escobar, “Estudio y simulación de sistemas de generación fotovoltaica utilizando matlab/simulink,” pp. 1–66, 2010.

10.1 Matriz de Estado del Arte

PRONÓSTICO DEL RECURSO SOLAR A CORTO PLAZO PARA DISTRITOS INDUSTRIALES BASADO EN REDES NEURONALES ARTIFICIALES																															
ITEM	DATOS		TEMÁTICA						FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETOS						RESTRICCIONES DEL PROBLEMA		PROPUESTAS PARA RESOLVER EL PROBLEMA			SOLUCIÓN PROPUESTA											
	AÑO	TÍTULO DEL ARTÍCULO	Tecnología Fotovoltaica	Modelo Matemático	Desempeño De Una Predicción	Redes Neuronales Artificiales	Predicción Energía Fotovoltaica	Radiación Solar	Modelos Empírico, Auto regresivo, Media móvil, Arima, etc.	Sistemas Fotovoltaicos	Fallas En La Toma De Datos En Estaciones Meteorológicas	Radiación Solar Observada diaria	Desempeño De Redes Neuronales	Característica Intrínseca De Producción de potencia	Demanda Eléctrica	Factores Externos	Factores Ambientales	Falta De Datos Climáticas	Herramienta De Predicción Solar.	Instalación Fotovoltaica	Resultados Menos Exactos	Modelo De Estimación y Algoritmo	RNA Multicapas	Base De Datos	Uso De Sensores	Datos De Pronóstico	RNA Para Modelar Estadísticamente	Formación De Base De Datos	Validación De Métodos	Permutar Las Variables	
1	2017	Estimación de Radiación Solar Horaria Utilizando Modelos Empíricos y Redes Neuronales Artificiales	(Jimenez et al., 2017)			x					x							x				x				x					
2	2017	PREDICCIÓN DE POTENCIA A CORTO PLAZO PARA PLANTAS FOTOVOLTAICAS UTILIZANDO REDES NEURONALES ARTIFICIALES	(Calle, 2017)	x		x	x	x					x						x			x					x				
3	2014	MODELOS DE PREDICCIÓN A CORTO PLAZO DE LA GENERACIÓN ELÉCTRICA EN INSTALACIONES FOTOVOLTAICAS	(Jiménez, 2014)				x	x	x	x				x						x		x						x			
4	2017	ESTIMACIÓN DE IRRADIANCIA EMPLEANDO REDES NEURONALES ARTIFICIALES CON VARIABLES METEOROLÓGICAS Y ELÉCTRICAS DE MÓDULOS FOTOVOLTAICOS	(Moo et al., 2017)				x	x	x							x			x				x					x			

10.2 Resumen de Indicadores




Figura 32. Resumen e indicador de la temática - Estado del arte.

FORMULACIÓN DEL PROBLEMA




Figura 33. Indicador de formulación del problema - Estado del arte.




Figura 34. Indicador de solución - Estado del arte.