

UCLV
Universidad Central
"Marta Abreu" de Las Villas



FIE
Facultad de
Ingeniería Eléctrica

Departamento de Electroenergética

TRABAJO DE DIPLOMA

Título: Predicción mediante redes neuronales artificiales de la producción de energía de un parque fotovoltaico

Autor: Yoelvis Llusa Ramos

Tutores: M.Sc. Reinier Herrera Casanova

Santa Clara, julio del 2019
Copyright©UCLV

UCLV
Universidad Central
"Marta Abreu" de Las Villas



FIE
Facultad de
Ingeniería Eléctrica

Electroenergetic Department

TRABAJO DE DIPLOMA

Title: Prediction by artificial neural networks of the energy production of a photovoltaic park

Author: Yoelvis Llusa Ramos

Thesis Director: M.Sc. Reinier Herrera Casanova

Este documento es Propiedad Patrimonial de la Universidad Central “Marta Abreu” de Las Villas, y se encuentra depositado en los fondos de la Biblioteca Universitaria “Chiqui Gómez Lubian” subordinada a la Dirección de Información Científico Técnica de la mencionada casa de altos estudios.

Se autoriza su utilización bajo la licencia siguiente:

Atribución- No Comercial- Compartir Igual



Para cualquier información contacte con:

Dirección de Información Científico Técnica. Universidad Central “Marta Abreu” de Las Villas. Carretera a Camajuaní. Km 5½. Santa Clara. Villa Clara. Cuba. CP. 54 830

Teléfonos.: +53 01 42281503-1419

PENSAMIENTO

“Un hombre con una idea nueva es un loco hasta que la idea triunfa.”

Mark Twain (1835-1910)

DEDICATORIA

A mis padres, que sin ellos este sueño nunca se hubiese convertido en realidad, por su sacrificio, apoyo incondicional y por su infinito AMOR que nunca me faltó, pero sobre todo por estar presente en todos los momentos de mi vida. Este también es su trabajo.

A mi hermano “Yohemnys Llusá Ramos” que siempre estuvo conmigo estos cinco años dándome todo su apoyo.

A mis abuelos que de una forma u otra siempre me acompañaron y me guiaron por el mejor camino.

A toda mi familia que siempre me supo dar los mejores consejos del mundo cuando no sabía qué hacer y que han hecho de mí un profesional.

AGRADECIMIENTOS

A mi tutor Reinier por el inmenso apoyo, por su gran profesionalidad y dedicación, por todos los conocimientos que transmite y por ayudarme a lograr esta meta.

A mi familia que nunca me dejó solo, a mis tíos, a mis abuelos y a mis primos que los considero como hermanos.

A todos los profesores porque gracias a ellos logramos ser grandes Profesionales. Gracias por su apoyo.

A mis compañeros por estos cinco años tan maravillosos. Por reír y llorar juntos, por haber compartido cosas únicas y maravillosas. Gracias por estar presente estos cinco años de mi vida.

En fin, a todas aquellas personas que emprendieron conmigo este viaje maravilloso que los tengo en mente, pero son tantos que no podría mencionarlos a todos.

Gracias a todos.

RESUMEN

La energía solar constituye actualmente una fuente de energía muy utilizada por el hombre. Sin embargo, presenta un comportamiento que en ocasiones resulta extremadamente difícil de prever. Debido a esto deben realizarse varios análisis con el fin de determinar la expectativa real de generación de los parques solares fotovoltaicos. La predicción de la energía que se produce en un parque solar fotovoltaico presenta una gran cantidad de aplicaciones, sobre todo en lo referente a la planificación y operación del sistema eléctrico. En el presente trabajo se realiza el diseño e implementación de una red neuronal artificial (RNA) mediante el software MATLAB, con el objetivo de realizar la predicción de la energía eléctrica que se produce en el parque fotovoltaico de Cruces en la provincia de Cienfuegos con el menor error posible. Los resultados que se obtienen muestran que las predicciones realizadas para diferentes períodos de tiempo y épocas del año son correctas, lo que demuestra la efectividad del método de predicción utilizado.

Palabras Clave: parque solar fotovoltaico; redes neuronales artificiales; predicción.

ÍNDICE

INTRODUCCIÓN.....	1
CAPÍTULO 1. ESTADO ACTUAL DE LA ENERGÍA SOLAR FOTOVOLTAICA Y LOS MÉTODOS DE PREDICCIÓN	4
1.1 Fundamentación teórica sobre la predicción de la generación de energía eléctrica en parques solares fotovoltaicos	4
1.2 Principios fundamentales de la energía solar fotovoltaica.....	5
1.2.1 Radiación solar	6
1.2.2 Fundamentos de la generación fotovoltaica	8
1.3 Predicción de la generación de energía en sistemas fotovoltaicos	11
1.3.1 Ventajas de la predicción	12
1.3.2 Horizontes de predicción.....	13
1.3.3 Incertidumbre en la predicción	14
1.4 Modelos de predicción.....	15
1.4.1 Estado actual de los modelos de predicción.....	15
1.4.2 Modelos de predicción basados en datos pasados	16
1.4.2.1 Modelos ARIMA.....	16
1.4.2.2 Sistemas de inferencia difusa o fuzzy	18
1.4.2.3 Redes neuronales artificiales (ANN)	19
1.4.2.4 Otros modelos	19
1.4.2.5 Modelos híbridos	21
1.4.3 Modelos de predicción basados en modelos atmosféricos.....	22
1.5 Consideraciones finales del capítulo.....	23
CAPÍTULO 2. PROGRAMA PARA LA PREDICCIÓN DE LA GENERACIÓN DE ENERGÍA ELÉCTRICA MEDIANTE REDES NEURONALES ARTIFICIALES	24
2.1 Redes neuronales artificiales.....	24
2.2 Elementos de una red neuronal artificial	25
2.3 Tipos de redes neuronales artificiales más utilizados para la predicción.....	27

ÍNDICE

2.4	Aprendizaje de las redes neuronales artificiales	28
2.5	Sobreentrenamiento de las redes neuronales artificiales	29
2.6	Red neuronal perceptrón multicapa (MLP)	30
2.7	Metodología general para el desarrollo de modelos de predicción.....	31
2.8	Diseño e implementación de la red neuronal artificial en MATLAB mediante la herramienta nntool	32
2.8.1	Elección del modelo de la red neuronal artificial.....	32
2.8.2	Selección de las variables de entrada y salida	33
2.8.3	Formación de los conjuntos de aprendizaje, test y validación	34
2.8.4	Pre-procesamiento de los datos.....	35
2.8.5	Entrenamiento de la red	36
2.8.6	Resultados del entrenamiento.....	39
2.9	Consideraciones finales del capítulo.....	41
CAPÍTULO 3. RESULTADOS DE LAS PREDICCIONES REALIZADAS.....		42
3.1	Descripción del parque solar fotovoltaico analizado.....	42
3.2	Resultados obtenidos para el período de tiempo analizado	43
3.3	Consideraciones finales del capítulo.....	53
CONCLUSIONES		55
RECOMENDACIONES		57
BIBLIOGRAFÍA.....		58
ANEXOS.....		60
Anexo I: Resultados de la predicción realizada por la red neuronal NARX		60
Anexo II: Resultados de la predicción promedio realizada por la red neuronal NARX.....		62
Anexo III: Resultados de la predicción realizada por el modelo ARIMA		64

INTRODUCCIÓN

Actualmente el planeta muestra un incremento de las necesidades energéticas, impulsadas por el desarrollo tecnológico y económico de la sociedad. Uno de los grandes problemas de la humanidad es su dependencia de los combustibles fósiles, ya que provocan un fuerte impacto ambiental, además de diversos cambios en el ámbito económico.

El reto está en conseguir que las energías alternativas y renovables sustituyan paulatinamente a los combustibles fósiles tradicionales. La principal ventaja de las energías renovables es la de su menor impacto ambiental, ya que, reducen el número de contaminantes a la atmósfera, además de su distribución territorial menos concentrada. Son fuentes continuas e inagotables de energía, por lo que son la alternativa del futuro.

Los sistemas fotovoltaicos conectados a las redes eléctricas constituyen una de las tecnologías de la generación distribuida de mayor impacto y crecimiento en los últimos años. Estos sistemas en los circuitos de distribución ofrecen beneficios ya que reducen las pérdidas en las redes e incrementan la confiabilidad y la calidad del suministro de energía eléctrica. Uno de los factores fundamentales que incide en las fluctuaciones de la tensión es la aparición de los huecos de generación (intervalos de tiempo donde la generación disminuye debido principalmente a variables atmosféricas), ocasionados por la nubosidad, este y otros problemas todavía no se resuelven satisfactoriamente con las fuentes de energía renovables, especialmente con altos niveles de generación.

Bajo estos conceptos varios análisis tienen que ser realizados con el fin de determinar la expectativa real de generación de las plantas fotovoltaicas. Uno de los motivos de la importancia que adquieren los diferentes modelos de predicción fotovoltaica es que la capacidad anual de energía solar fotovoltaica en el mundo se ha incrementado exponencialmente en los últimos diez años. Hoy en día, se trata del tipo de energía más barata en un gran número de países debido a que se han abaratado sustancialmente los costos de producción de módulos fotovoltaicos [1].

La predicción de la energía producida por un parque fotovoltaico presenta una gran cantidad de aplicaciones tanto para la planificación como para la instalación de plantas fotovoltaicas. En este sentido, la aplicación de algoritmos de predicción que dan una aproximación de la generación prevista, representa un reto para los ingenieros eléctricos.

En diferentes publicaciones internacionales se aborda este tema. En la referencia [2] se realiza la predicción de la generación fotovoltaica mediante técnicas estadísticas y modelos de regresión. Otros trabajos [3], [4], [5] emplean modelos Auto Regresivos de Media Móvil e Integrados (ARIMA) para realizar dicha predicción. Un gran número de publicaciones [6-11] utilizan técnicas de inteligencia artificial para este fin, fundamentalmente redes neuronales artificiales basadas en perceptrón multicapa (MLP).

La dependencia que tiene la energía eléctrica que se genera en un parque solar fotovoltaico de las condiciones meteorológicas y la alta variabilidad de estas, hacen que el problema de la predicción de la energía que se genera en el mismo sea una labor compleja. Sobre todo, la naturaleza intermitente de la cobertura de nubes origina que, incluso para horizontes temporales pequeños, sea difícil asegurar cuál va a ser exactamente el valor de la radiación incidente sobre el parque en cuestión [12].

Este tema posee una gran importancia y actualidad, pues si se realiza un pronóstico adecuado de la generación de las fuentes renovables de energía, se puede lograr una integración exitosa de estas fuentes renovables al Sistema Electroenergético Nacional (SEN), lo que permitiría una adecuada planificación y operación del sistema eléctrico.

Cuba actualmente cuenta con 40 parque solares fotovoltaicos (PSF) sincronizados al SEN y se prevé que para el año 2030, las fuentes renovables de energía representen el 24 % de la matriz energética. Por lo que deben incrementarse el número de instalaciones fotovoltaicas en todo el país.

El parque solar fotovoltaico de Cruces, en la provincia de Cienfuegos, posee una potencia nominal de 3 MW. Se dispone de un amplio grupo de mediciones de las variables siguientes: radiación solar, temperatura ambiente, temperatura de los módulos fotovoltaicos y potencia generada. Es decir, se tienen los elementos necesarios para realizar el estudio en este parque fotovoltaico.

A partir de todo lo anterior, se plantea como **problema de investigación**: ¿Cómo predecir la generación de energía eléctrica en el parque solar fotovoltaico de Cruces?

De acuerdo al problema de investigación, se traza como **objetivo general**:

- ✓ Predecir la generación de energía eléctrica en el parque solar fotovoltaico de Cruces, mediante una red neuronal artificial implementada en el software MATLAB.

Para dar cumplimiento al mismo, se declaran como **objetivos específicos**:

1. Analizar la bibliografía relacionada con los métodos utilizados para la predicción de la generación de energía eléctrica en parques solares fotovoltaicos.
2. Diseñar una red neuronal artificial mediante la herramienta *nntool* (*neural network toolbox*) de MATLAB.

3. Entrenar la red neuronal artificial a través de los datos disponibles.
4. Evaluar el comportamiento de la red neuronal mediante la predicción de la generación de energía en el parque solar fotovoltaico en diferentes períodos de tiempo.

Las **tareas científicas** que contribuyen al cumplimiento de los objetivos específicos son:

1. Realización de una búsqueda bibliográfica sobre el tema.
2. Análisis de los principales métodos utilizados para la predicción de la generación de energía en parques solares fotovoltaicos.
3. Recopilación de las mediciones del parque solar fotovoltaico.
4. Diseño e implementación de una red neuronal artificial a partir de los datos disponibles y la herramienta *nntool* de MATLAB.
5. Entrenamiento de la red neuronal artificial.
6. Evaluación de la predicción de la generación de energía en el parque solar fotovoltaico en diferentes períodos de tiempo y épocas del año.

La principal contribución del trabajo radica en el desarrollo de una metodología sencilla pero efectiva para el logro del objetivo propuesto con el mínimo error posible, la cual resulta aplicable en cualquier parque solar fotovoltaico.

La estructura del trabajo está compuesta por introducción, tres capítulos, conclusiones, recomendaciones, bibliografía y anexos.

El primer capítulo aborda el estado del arte de los diferentes métodos predictivos utilizados a nivel mundial para la predicción de la generación de energía eléctrica en parques solares fotovoltaicos según la literatura internacional, así como los fundamentos de la generación de energía eléctrica mediante el empleo de módulos fotovoltaicos.

El segundo capítulo corresponde al desarrollo de la red neuronal artificial mediante la herramienta *nntool* de MATLAB, su entrenamiento y validación. Se explica la estructura de una red neuronal, así como los tipos de redes más recomendados para la predicción y el entrenamiento que se utiliza en las mismas.

En el tercer capítulo se describe el parque solar fotovoltaico escogido para realizar la predicción y los resultados obtenidos para diferentes épocas del año.

CAPÍTULO 1. ESTADO ACTUAL DE LA ENERGÍA SOLAR FOTOVOLTAICA Y LOS MÉTODOS DE PREDICCIÓN

En este capítulo se analizan los principios y fundamentos de la energía solar fotovoltaica, así como lo correspondiente al estado del arte de los modelos de predicción de la producción eléctrica de los parques solares fotovoltaicos. Se describen algunos de los modelos referidos en artículos publicados en la literatura internacional, con las limitaciones de dichos modelos de predicción y sus resultados.

1.1 Fundamentación teórica sobre la predicción de la generación de energía eléctrica en parques solares fotovoltaicos

Diferentes publicaciones internacionales han abordado el tema de la predicción de las diferentes variables asociadas a sistemas fotovoltaicos.

En la referencia [2] se compara un método de predicción de potencia aplicada a un parque solar fotovoltaico basado en regresiones múltiples con técnicas basadas en redes neuronales. En la referencia [3] se comparan un modelo (ARIMA) con otras técnicas más avanzadas de inteligencia artificial para horizontes de predicción de muy corto y corto plazo.

En [4] se utiliza un modelo auto-regresivo de media móvil (ARMAX) para predecir la potencia media diaria que genera parque fotovoltaico con un horizonte de predicción de 24 horas.

En la referencia [5] se comparan varios modelos ARIMA con otras técnicas más avanzadas para predecir la radiación solar con un horizonte de predicción de corto plazo.

En [6] se realiza la predicción de la potencia eléctrica media de un parque fotovoltaico para horizontes de hasta 24 horas, para esto se utiliza el método de máquina de soporte de vectores y una red neuronal artificial del tipo MLP con una capa oculta.

En la referencia [7] se realiza la predicción de la potencia eléctrica media horaria de una instalación fotovoltaica para un horizonte de una hora, para eso se utiliza una red neuronal basada en MLP y entrenada con el algoritmo de propagación de errores hacia atrás (BP).

En [8] se utiliza una red neuronal artificial para la predicción de generación en una planta termosolar con un horizonte de predicción de muy corto plazo.

En [9] se utiliza una red neuronal unidireccional con dos capas ocultas, entrenada con el algoritmo de retropropagación de *Levenberg-Marquardt* para predecir la potencia media generada en un parque fotovoltaico con un horizonte de predicción de seis horas.

Un procedimiento similar al de la referencia [9] se desarrolla en [10], donde se utiliza también una red neuronal basada en MLP para la predicción de la potencia de salida de tres tipos diferentes de celdas solares.

Por su parte la referencia [11] realiza un estudio mediante una red neuronal MLP para la predicción de la generación de un parque solar fotovoltaico ubicado en la Universidad de Salento.

1.2 Principios fundamentales de la energía solar fotovoltaica

Este tipo de energía posee una gran cantidad de aplicaciones. Debido a la creciente demanda de energías renovables, la fabricación de células solares e instalaciones fotovoltaicas ha avanzado considerablemente en los últimos años. Entre los años 2001 y 2018 se ha producido un crecimiento exponencial de la producción de energía fotovoltaica, duplicándose aproximadamente cada dos años (figura 1.1). La potencia total fotovoltaica instalada en el mundo (conectada a la red) ascendía a 16 GW en 2008, 40 GW en 2010, 100 GW en 2012 y 140 GW en 2013. A finales de 2017, se habían instalado en todo el mundo cerca 282GW, lo que aumentó a 321 GW en el año 2018.




Figura 1.1. Comportamiento de la potencia fotovoltaica instalada a nivel mundial en los últimos 18 años [12].

La energía solar fotovoltaica se ha convertido en la tercera fuente de energía renovable más importante en términos de capacidad instalada a nivel global, después de las energías hidroeléctrica y eólica. Este tipo de energía se supone ya una fracción significativa del mercado

eléctrico en la Unión Europea, donde cubre aproximadamente el 3,5 % de la demanda de electricidad y alcanza el 7 % en los períodos de mayor producción. En algunos países, como Alemania, Italia o España, alcanza máximos superiores al 10 %, al igual que en Japón o en algunos lugares soleados de Estados Unidos, como California.

Una de las principales aplicaciones de la energía solar fotovoltaica más desarrollada en los últimos años, consiste en los parques conectados a red para suministro eléctrico, así como los sistemas de autoconsumo fotovoltaico, de potencia generalmente menor, pero igualmente conectados a la red eléctrica.

Su característica principal es que la totalidad de la electricidad producida se vierte a la red eléctrica para un consumo en otro lugar. El productor recibe una compensación financiera por la energía suministrada a la red.

1.2.1 Radiación solar

La radiación solar es el conjunto de radiaciones electromagnéticas emitidas por el sol. El sol es una estrella que se encuentra a una temperatura media de 6000 K, en cuyo interior tienen lugar una serie de reacciones de fusión nuclear que producen una pérdida de masa que se transforma en energía. Esta energía liberada del sol se transmite al exterior mediante la radiación solar cercana a la equivalente a un cuerpo negro [13], [14].

La irradiación solar [12] es la magnitud que se emplea para indicar el valor de la radiación incidente en una superficie. En el caso del sol, se define como la energía solar que recibe cada m^2 en un segundo. A lo largo de un día la potencia de la radiación varía en función de diferentes parámetros, como las condiciones meteorológicas y atmosféricas, la rotación de la tierra y la inclinación de los rayos solares.

La radiación solar en la cima de la atmósfera terrestre, en dirección perpendicular a los rayos solares, tienen un valor medio de 1367 W/m^2 y se denomina constante solar porque se mantiene prácticamente constante durante decenas o centenares de años, ya que, al ser básicamente dependiente de factores astronómicos o astrofísicos, su variación es muy lenta [12], [13], [14]. Aunque la radiación de la superficie del sol sea prácticamente constante, a su paso por la atmósfera, la radiación solar se atenúa debido a procesos de absorción y difusión que producen los gases y partículas de la atmósfera y las nubes. La radiación solar incidente en la superficie de la tierra no suele superar los 1000 W/m^2 , esto depende mucho del lugar, la hora del día, la época del año y el estado del cielo.

La radiación solar que atraviesa la atmósfera es atenuada alrededor de un 30 % hasta alcanzar la superficie terrestre debido a efectos que se describen a continuación:

- Dispersión *Rayleigh*, se produce por la interacción con moléculas atmosféricas y otras partículas pequeñas cuyo diámetro es menor que la longitud de onda de la radiación incidente. La longitud de onda más corta tiende a ser más afectada por esta modalidad de dispersión, que las longitudes de onda más largas.
- Dispersión por aerosoles y partículas de polvo.
- La absorción por los gases atmosféricos tales como oxígeno, ozono, vapor de agua y dióxido de carbono.

La radiación solar global que incide en el suelo está compuesta por la radiación directa, que es el haz que llega a la superficie terrestre en una línea directa desde el sol, y la radiación difusa del cielo, que se crea cuando una parte de la radiación del haz directo es dispersada por los elementos presentes en la atmósfera (figura 1.2).




Figura 1.2. Radiación directa y difusa [12].

La radiación directa es la que mayor energía produce al incidir sobre la célula fotovoltaica, varía con el coseno del ángulo cenital del sol y depende de la cobertura de nubes. Predomina para cielos despejados o claros y fundamentalmente en las horas centrales del día. La radiación difusa posee menor influencia en la producción de energía y su valor depende de la nubosidad. Predomina fundamentalmente en los crepúsculos o cuando el sol está oculto por las nubes. La suma de la radiación solar directa y difusa se llama radiación global. Además, a la hora de concretar cuánta radiación incide sobre un cuerpo hay que tener en cuenta también la radiación reflejada (figura 1.3) [12],[15].



Figura 1.3. Radiación incidente sobre un panel fotovoltaico [12].

1.2.2 Fundamentos de la generación fotovoltaica

La energía solar fotovoltaica es aquella que se obtiene a través de la transformación directa de la energía del sol en energía eléctrica. El principal encargado de dicha transformación es el panel fotovoltaico [12].

El efecto fotovoltaico fue reconocido por primera vez en 1839 por el físico francés *Alexander-Edmond Becquerel*, pero se tuvo que esperar casi medio siglo para que se fabricara la primera célula solar. Su creador fue *Charles Fritts* en el año 1883, quien recubrió una muestra de selenio semiconductor con oro para formar la unión. Este dispositivo presentaba una eficiencia menor del 1 % y un costo de producción muy alto que se debía al precio de los materiales. Pero demostró de forma práctica que era posible producir electricidad con la luz del sol. Los estudios realizados en el siglo XIX por *Michael Faraday*, *James Clerk Maxwell*, *Nikola Tesla* y *Heinrich Hertz* sobre inducción electromagnética, fuerzas eléctricas y ondas electromagnéticas, y sobre todo los de *Albert Einstein* en 1905, proporcionaron la base teórica al efecto fotoeléctrico, que es el fundamento de la conversión de energía solar a electricidad [12], [16],[17].

El ingeniero estadounidense *Russell Ohl* patentó la célula solar moderna en el año 1946, aunque otros investigadores habían avanzado en su desarrollo con anterioridad. El físico sueco *Sven Ason Berglund* había patentado en 1914 un método que trataba de incrementar la capacidad de las células fotosensibles, mientras que, en 1931, el ingeniero alemán *Bruno*

Lange desarrolla una fotocélula mediante el uso de seleniuro de plata en lugar de óxido de cobre [16].

Los paneles fotovoltaicos están compuestos por módulos y estos a su vez por células fotovoltaicas. Las células solares fotovoltaicas convencionales están formadas por una o varias láminas de material semiconductor y recubiertas de un vidrio transparente que deja pasar la radiación solar y minimiza las pérdidas de calor.

Las fabricadas de silicio son bastantes eficientes, con unos rendimientos medios de 14-17%, aunque también más caras de producir por la alta dependencia en la disponibilidad del silicio. El abaratamiento del costo de los paneles fotovoltaicos se muestra en la figura 1.4. Esto propicia que esta tecnología sea en un futuro próximo competitiva, en términos económicos, con respecto a las tecnologías de generación de energía basadas en combustibles fósiles. También se investigan y utilizan otros materiales más baratos (denominados células de segunda generación) aunque sus rendimientos son ligeramente inferiores [12].




Figura 1.4. Evolución del costo de los módulos solares de silicio (euro/Watts).

Dentro de las células fotovoltaicas de silicio se destacan [11]:

- Silicio monocristalino: se obtiene del silicio puro fundido y dopado con boro. Se caracteriza por tener un color azul homogéneo y por la conexión de las células individuales entre sí (figura 1.5a). Bajo ensayos de laboratorio el rendimiento de los módulos es del 24%, sin embargo, una vez instalados suelen alcanzar un rendimiento real del 18%. Se trata del tipo de módulo con mayor rendimiento y el que tiene una mayor vida útil, pero también es el más caro debido a su tecnología de fabricación y a su alta pureza.

- Silicio policristalino: se obtiene del silicio puro fundido, la principal diferencia es que el policristalino reduce el número de fases de cristalización. Se caracteriza por su superficie estructurada en cristales y las diferentes tonalidades azules que lo forman (figura 1.5b). En laboratorio, el rendimiento es de un 20%, sin embargo, en el terreno suele alcanzar un rendimiento del 14%. Puesto que tiene un método de fabricación más simple, resulta más barato que el monocristalino, pero tiene el inconveniente de que es menos resistente al calor por lo que a altas temperaturas funciona peor que un módulo monocristalino.
- Silicio amorfo: El silicio amorfo no tiene estructura cristalina, si no que se deposita en forma de lámina sobre un sustrato (figura 1.5c). Se caracteriza por su color homogéneo marrón y la ausencia de conexión visible entre las células. Tiene un 16% de rendimiento en laboratorio, y una vez instalado no llega al 10%. Debido a su bajo precio, se utiliza sobre todo para pequeña electrónica de consumo.




Figura 1.5. Células solares fotovoltaicas de silicio, (a) monocristalino, (b) policristalino y (c) amorfo [11].

El proceso de obtención de energía eléctrica a través de un sistema fotovoltaico es sencillo. La luz del sol que está compuesta por fotones incide en las células fotovoltaicas de la placa, se crea de esta forma un campo eléctrico entre las capas. Cuanto mayor sea la radiación incidente, mayor es la energía producida. Cada célula fotovoltaica está compuesta de, al menos, dos delgadas láminas de silicio. Una dopada con elementos que tienen menos electrones de valencia que el silicio, denominada P y otra con elementos que tienen más electrones que los átomos de silicio, denominada N . Los fotones procedentes de la fuente luminosa, inciden sobre la superficie de la capa P y al interactuar con el material liberan

electrones de los átomos de silicio los cuales, en movimiento, atraviesan la capa de semiconductor, pero no pueden volver. La capa N adquiere una diferencia de potencial respecto a la P . El campo eléctrico establecido a través de la creación de la unión $P-N$ crea un diodo (figura 1.6) que permite el flujo de corriente en un solo sentido a través de dicha unión. Los electrones pueden pasar del lado tipo N hacia el interior del lado P , y los huecos pueden pasar del lado tipo P hacia el lado tipo N . Esta región donde los electrones se han difundido en la unión se llama región de agotamiento porque solamente contiene portadores de carga móviles. Es también conocida como la región de cargas [12], [11].




Figura 1.6. Circuito equivalente de un panel fotovoltaico [11].

Las células fotoeléctricas transforman la energía solar en electricidad en forma de corriente continua, y esta suele transformarse a corriente alterna mediante un inversor para su aprovechamiento. El inversor transforma la corriente continua en corriente alterna con las mismas características de la red eléctrica a la que va a verterse, y controla la uniformidad y calidad de la señal [11].

La eficiencia de un panel solar fotovoltaico (η), se define o se toma como el porcentaje de potencia convertida en energía eléctrica de la luz solar total absorbida por un panel. Este parámetro se calcula mediante la relación del punto de potencia máximo, P_m , dividido entre la radiación incidente (RAD) y el área superficial del panel (A):

$$\eta = \frac{P_m}{RAD * A} \quad (1.1)$$

Otro término para definir la eficiencia de una célula solar es el factor de llenado o *fill factor* (FF), que se define como la relación entre el punto de máxima potencia dividido entre el voltaje de circuito abierto (V_{oc}) y la corriente de cortocircuito (I_{cc}):

$$FF = \frac{P_m}{V_{oc} * I_{cc}} = \frac{\eta * RAD * A}{V_{oc} * I_{cc}} \quad (1.2)$$

1.3 Predicción de la generación de energía en sistemas fotovoltaicos

Actualmente una de las características distintivas de la energía eléctrica generada en parques solares fotovoltaicos es su carácter no gestionable, debido fundamentalmente a un régimen

de generación eléctrica con alta intermitencia en función de la evolución de las condiciones climatológicas, sobre todo de la cobertura de nubes que puede presentar importantes cambios en intervalos cortos de tiempo; imposibilidad de control de la producción eléctrica ya que se genera toda la energía eléctrica que el sol aporte, sin que sea posible aumentar esa energía eléctrica; y escasa fiabilidad en los valores futuros de la producción de energía eléctrica frente a los programas de la generación eléctrica de las centrales clásicas no obstante, los últimos avances científicos permiten simular el comportamiento de la atmósfera y el océano mediante modelos, que, junto con el incremento de la potencia de cálculo en las nuevas computadoras, logran realizar unas predicciones del tiempo cada vez más exactas.

La predicción de la generación fotovoltaica permite llevar a cabo una planificación energética apropiada, lo que ayuda a realizar un cálculo de la reserva de generación, y por lo tanto tiene consecuencias económicas positivas. Además, otro de los motivos de la importancia de la predicción es poder dar solución a los problemas que pueden surgir en la red eléctrica.

En los últimos diez años junto con el desarrollo de la energía solar fotovoltaica se han estudiado disímiles modelos de predicción, entre los que se destacan fundamentalmente el uso de modelos grises, redes neuronales artificiales, modelos atmosféricos, modelos difusos, modelos híbridos, modelos ARIMA, entre otros.

1.3.1 Ventajas de la predicción

Los sistemas eléctricos de potencia presentan como problema característico la imposibilidad de poder almacenar energía eléctrica a gran escala. Además, la fiabilidad de un sistema eléctrico radica en asegurar el suministro continuo de la energía eléctrica a sus clientes con el mínimo de interrupciones posibles. Es evidente que desde la puesta en funcionamiento de los sistemas eléctricos se hace necesario disponer de métodos de predicción de valores futuros de la demanda de energía eléctrica.

Precisamente una de las primeras variables que fue objeto de atención por los especialistas fue la demanda de energía eléctrica. La predicción de esta variable se utiliza para la planificación de la energía eléctrica producida, en las compras de combustibles para las centrales eléctricas, para la secuenciación de los períodos de mantenimiento de los elementos del sistema eléctrico y para la planificación de las redes eléctricas.

El creciente aumento de la interconexión de los parques solares fotovoltaicos a los sistemas eléctricos trae como consecuencia disponer de herramientas para la predicción de la generación eléctrica en parques solares fotovoltaicos, por las repercusiones económicas que

un conocimiento de antemano de los valores de energía generada puede tener en la determinación de la programación de las centrales eléctricas clásicas, y en las unidades generadoras convencionales.

Por lo tanto, existe una doble necesidad de predicción de la energía eléctrica producida en los parques solares fotovoltaicos: por una parte, el operador del sistema eléctrico necesita conocer de antemano la potencia eléctrica que se va a inyectar en el sistema para un período de programación sobre una base horaria; y, además, el operador necesita el nodo en el que se va a inyectar esa potencia eléctrica para poder realizar los análisis del funcionamiento previsto del sistema [12].

1.3.2 Horizontes de predicción

El horizonte de predicción se considera como el período de tiempo que determina el momento futuro para el que se realizan las predicciones, el cual se debe tomar en cuenta desde el primer momento de diseño para el desarrollo de cualquier modelo de predicción.

No existe unanimidad en cuanto al horizonte de predicción que debe ser utilizado para el desarrollo de cualquier modelo de predicción, ya sea para la predicción de generación de potencia eléctrica en parques solares fotovoltaicos, como para otras aplicaciones.

Según [12], [18-20] se pueden clasificar en:

- Predicción a muy corto plazo: el horizonte de predicción es de unas horas, no existe unanimidad en su valor, así, como en sus valores extremos. La referencia [19] propone cuatro horas, mientras la [18] propone nueve horas. Para el operador de la red eléctrica estas predicciones son de interés para el mantenimiento de la seguridad del sistema eléctrico.
- Predicción a corto plazo: el horizonte de predicción abarca desde el límite con el de muy corto plazo hasta las 48 ó 72 horas. Esta predicción es la de mayor interés para poder actuar en el mercado diario eléctrico [20].
- Predicciones a largo plazo: corresponden a un horizonte por encima de las 48 ó 72 horas y llegan hasta un límite de siete días. Cuanto mayor sea el horizonte, mayores son los errores de predicción, pues hoy en día resulta difícil realizar predicciones fiables de variables atmosféricas por encima de esos siete días. Estas predicciones pueden ser de interés en la programación del sistema de generación de centrales eléctricas convencionales, o en la programación de las labores de mantenimiento de esas centrales [20].

Algunas bibliografías como [18] proponen además un horizonte de predicción de mediano plazo que contempla los límites entre tres a cinco días principalmente para su uso en la programación del sistema de generación de centrales eléctricas convencionales.

Dada la importante trascendencia económica del tema, la mayor parte de los trabajos publicados [8, 9, 12, 17, 20, 21] se han centrado en la predicción de la generación eléctrica a corto plazo, sobre todo para el día siguiente (24 horas).

1.3.3 Incertidumbre en la predicción

Los modelos que se usan para las predicciones de la generación eléctrica pueden emplear como datos de entrada variables meteorológicas que influyan sobre el comportamiento de la producción del parque solar fotovoltaico que se analiza (radiación solar, temperatura ambiente, humedad relativa, cobertura de nubes, posición y altitud del sol, presión, entre otras). Estos datos meteorológicos se obtienen principalmente de las predicciones meteorológicas generadas por los modelos atmosféricos. Estos son, generalmente, propiedad de los institutos meteorológicos nacionales, que proporcionan las predicciones de los valores numéricos de las variables meteorológicas. A partir de estos valores numéricos, se calcula la predicción de la potencia eléctrica generada en un parque solar fotovoltaico mediante el uso de métodos estadísticos o simplemente algún modelo de predicción existente. Pero la predicción de la generación eléctrica de estos últimos modelos tiene una gran limitación: los modelos de predicción de la generación eléctrica no pueden mejorar las predicciones de los modelos atmosféricos.

Las principales fuentes de error en los modelos atmosféricos pueden ser desde un deficiente modelado de la superficie del terreno, hasta condiciones iniciales incorrectas, consecuencia de errores en el proceso de medida o interpretación de las variables meteorológicas que define el estado de partida de la atmósfera. El error causado por un deficiente modelado de la superficie del terreno, puede ser corregido estadísticamente. El error por condiciones iniciales incorrectas no puede ser corregido de antemano y es responsable de diferencias importantes entre los valores de predicción y los reales [12].

Por lo tanto, se puede decir que la predicción de la potencia eléctrica generada por un parque solar fotovoltaico constituye una tarea difícil, no exenta de importantes errores. Pero a pesar de su dificultad, resulta imprescindible, tanto desde el punto de vista técnico como económico.

1.4 Modelos de predicción

1.4.1 Estado actual de los modelos de predicción

Hasta el año 2010 la investigación y el desarrollo de modelos de predicción de generación fotovoltaica era mínima. La mayor parte de los modelos se basaban en la predicción de la radiación que incide sobre el parque solar fotovoltaico y se calculaba la potencia eléctrica producida a partir de dichos valores. Para esto generalmente se utiliza las curvas proporcionadas por el fabricante del panel solar fotovoltaico o una serie de ecuaciones o relaciones empíricas conocidas [20]. A partir del año 2011 la publicación de nuevos modelos de predicción fotovoltaicos ha crecido considerablemente debido al aumento exponencial en los últimos diez años de la energía solar fotovoltaica en todo el mundo, así como los estudios sobre las características de dicha fuente de energía.

Hoy en día, gracias al desarrollo alcanzado por los diferentes modelos utilizados para la predicción se puede realizar varias clasificaciones que dependen del criterio que se tenga en cuenta. Algunos criterios consideran la linealidad del modelo y los clasifica en lineales y no lineales. Otros toman en cuenta el método utilizado para el desarrollo matemático del modelo y los clasifican en modelos basados en técnicas de inteligencia artificial o en modelos regresivos. Aunque la clasificación más adecuada según [12] para comparar los datos de forma apropiada es:

- Modelos basados en valores pasados: utilizan como entrada únicamente valores pasados, que pueden ser únicamente de la variable a predecir o de la variable a predecir complementada con otras variables que puedan influir sobre la misma. Dentro de estas variables se pueden incluir no solo las correspondientes al instante de tiempo en que se dieron, sino que pueden tratarse de variables meteorológicas medidas localmente en dichos instantes pasados.
- Modelos atmosféricos: estos modelos incorporan como entrada los valores de predicción de variables meteorológicas obtenidas por los programas de predicción numérica existentes en diferentes institutos meteorológicos, además, dichas entradas pueden estar complementadas por las indicadas en el grupo anterior.

1.4.2 Modelos de predicción basados en datos pasados

1.4.2.1 Modelos ARIMA

El análisis de series temporales puede emplearse para comprender el comportamiento de una serie de datos observada o para predecir valores futuros de esta serie. Los modelos ARIMA (de las siglas en ingles de *Auto Regressive Integrated Moving Average*) son una herramienta común para la predicción de series temporales.

Suponen que los valores pasados de la serie, llamados historia de la serie, influyen en el futuro de la serie a través de una combinación de elementos autorregresivos (AR) y de media móvil (MA). En un proceso auto regresivo puro, los valores futuros de la serie solo dependen de valores pasados. En el proceso de medias móviles, los valores futuros de la serie dependen de variables aleatorias, independientes unas de otras y que se modelan como ruido blanco. Los modelos ARIMA se denominan integrados porque puede ser necesario un paso previo de diferenciación de la serie para eliminar comportamientos no estacionarios [22].

Dentro de los modelos ARIMA destacan:

- Modelos auto-regresivos: El valor de la variable en un instante t es demostrado por las observaciones de ella misma correspondiente a instantes anteriores añadiéndose un término de error (ecuación 1.3). Hay que tener en cuenta que se trata de modelos lineales por lo que X_t se expresa como una combinación lineal de sus valores pasados (parte sistemática) más un término de error (innovación).

$$\phi_p(B)X_t = \phi_0 + e_t \quad (1.3)$$

Donde:

$\phi_p(B)$: operador polinomial de retardo.

ϕ_0 : combinación lineal de los valores pasados

e_t : término de error.

- Modelos de media móvil: es aquel que explica el valor de una determinada variable en un período t en función de un término independiente y una sucesión de errores correspondientes a períodos precedentes, ponderados convenientemente. Estos modelos se denotan normalmente con las siglas MA, seguidos, como en el caso de los modelos auto - regresivos, del orden entre paréntesis. Así, un modelo con q términos de error MA(q), responde a la ecuación siguiente:

$$X_t = \theta_q(B)e_t + \mu \quad (1.4)$$

Donde:

$\theta_q(B)$: polinomio de retardo.

e_t : error.

μ : constante numérica.

- Modelos ARMA: Este modelo es la combinación del modelo auto-regresivo y el de media móvil, de ahí que se denomina ARMA (auto-regresivo y de media móvil). Para obtener su expresión basta con combinar las expresiones de los modelos mencionados respectivamente:

$$\phi_p(B)X_t = \phi_0 + \theta_q(B)e_t \quad (1.5)$$

- Modelos ARIMA: Cuando una serie presenta un comportamiento periódico o una tendencia determinística, se puede representar por medio del modelo ARMA combinado con el operador diferencial, lo que da lugar al modelo general ARIMA (p, d, q).

De esta forma se puede decir que se realiza una transformación de la serie original X de la variable a predecir, en otra, Y, que ya no presenta ese comportamiento periódico o que es estacionario, tal como muestra la ecuación 1.6.

$$\phi_p(B)(1 - B)^d X_t = \phi_0 + \theta_q(B)e_t \quad (1.6)$$

- Modelos ARIMA con estacionalidad: El último componente que se añade a los modelos ARIMA, es el más complejo, la estacionalidad (el patrón de comportamiento periódico de la serie temporal se incrementa con el tiempo). El modelo resultante se conoce como modelo ARIMA con estacionalidad multiplicada, para ello se introducen unos nuevos términos: auto-regresivo P, diferenciación D y de media móvil Q, todos ellos referidos a los valores retrasados en el tiempo un múltiplo del índice de estacionalidad s (ecuación 1.7).

$$\phi_p(B)\phi_p(B^s)(1 - B^s)^D(1 - B)^d X_t = \phi_0 + \theta_q(B)\theta_q(B^s)e_t \quad (1.7)$$

Los coeficientes derivados de $\phi_p(B^s)$ y $\theta_q(B^s)$ están referidos a la parte estacionaria.

Los modelos ARIMA pese a tener un cálculo complejo, es fácil encontrar herramientas computacionales para su desarrollo. Por otra parte, permite proporcionales intervalos de confianza en sus predicciones con base estadística fiable. Sus mayores aplicaciones radican en las esferas económicas.

El inconveniente de los modelos ARIMA es su carácter lineal, lo cual dificulta que se puedan modelar de manera adecuada todos los problemas. En el caso de la generación eléctrica fotovoltaica tiene carácter no lineal por lo que se recomienda su uso solo en estudios donde se comparan varios métodos predictivos como un modelo más con que se puede comparar o

en predicciones donde el valor del error fuera más permisible. Son modelos muy sensibles a *outliers* (datos de medición erróneos), lo que obliga a revisar detalladamente la serie temporal para detectarlos y corregirlos antes de diseñar el modelo de predicción. Cabe destacar la necesidad de tener gran experiencia y conocimiento de las series de tiempo en el desarrollo de modelos de predicción [12].

1.4.2.2 Sistemas de inferencia difusa o fuzzy

La lógica difusa es una lógica alternativa a la binaria debido a que, en el mundo real, existe mucha información que es ambigua o imprecisa y que no puede ser tratada en su totalidad como un valor verdadero o falso. La lógica difusa fue creada necesariamente para imitar el razonamiento del ser humano. Iniciada en 1965 por el profesor *Lofti A. Zadeh*, surgió como una importante herramienta para el desarrollo de sistemas de control y procesos industriales complejos [23].

La lógica bivalente permite trabajar con información definida y precisa, una afirmación es verdadera o falsa y no toma valores intermedios. La lógica difusa es un concepto mucho más extenso, debido a que puede tomar valores entre cero y uno, y permite trabajar con información que no es exacta para poder definir evaluaciones convencionales.

Este tipo de sistema quizás es el más sencillo de comprender, puesto que se basa en un razonamiento inductivo, presente en muchos procesos intelectuales humanos. Los más representativos son los razonamientos que responden a estructuras lógicas del tipo “Si, entonces ...”. Una regla de este tipo relaciona las variables asociadas al “Si” (antecedentes o causas) con las variables asociadas al “entonces” (consecuencia o efecto) [24].

Los sistemas de inferencia difusa tienen la capacidad de integrar términos lingüísticos en el razonamiento, además permite ajustar los parámetros de dicho sistema y reducir los errores si se utiliza como aproximador de funciones.

En cuanto a su desventaja cabe destacar que desde el principio se deben fijar las reglas que establecen el funcionamiento del sistema, y en ocasiones, un cambio de condiciones puede requerir la creación de un nuevo sistema de inferencia difusa ya que no son capaces de aprender.

En cuanto a la predicción de generación eléctrica en parque solares fotovoltaicos los resultados son similares a los que se obtienen con redes neuronales artificiales.

1.4.2.3 Redes neuronales artificiales (ANN)

Los modelos basados en redes neuronales artificiales se desarrollaron a partir de 1940 gracias al trabajo de *Warren McCulloch* y *Walter Pitts*.

Las redes neuronales artificiales consisten en un modelo matemático basado en el sistema nervioso biológico, formado por un gran número de elementos simples que procesan información mediante su estado dinámico como respuesta a entradas externas. Las unidades básicas del modelo son las neuronas. Cada una de estas neuronas está interconectada con las entradas de la red neuronal y con los diferentes elementos del modelo, además de tener un peso asociado. Las etapas principales del modelado basado en redes neuronales son: elección de las variables de entrada, tipo de red y número de capas, preparación del conjunto de datos, creación de la red neuronal, entrenamiento de la red neuronal y validación de los resultados. Las series de tiempo de la carga eléctrica son usualmente funciones no lineales de variables externas, por lo que, debido a esta no linealidad, las redes neuronales artificiales reciben gran atención en la solución de problemas de este tipo [23].

Las redes neuronales artificiales están formadas por un amplio grupo de modelos que dependen en concreto del tipo de neurona que se utilice, de la arquitectura o topología de la conexión, y del algoritmo de aprendizaje.

Los modelos basados en redes neuronales artificiales no requieren de gran experiencia previa como ocurría con los modelos ARIMA. En caso de existir cambios en el conjunto de datos de entrada, la red neuronal se puede readaptar entrenando nuevamente la red. Además, no es preciso conocer la naturaleza del conjunto de datos ya que las redes neuronales artificiales recogen las características principales de dicho conjunto a través del entrenamiento.

Su principal desventaja radica en la necesidad de disponer de gran cantidad de datos para el proceso de entrenamiento. En muchos casos resulta difícil obtener la cantidad de datos necesarios para que se logre un entrenamiento adecuado.

Dentro de las redes neuronales artificiales la gran mayoría de los estudios se realizan con redes del tipo perceptrón multicapa (MLP). Un MLP puede aproximar relaciones no lineales entre los datos de entrada y salida, además se considera como el aproximador universal de funciones por excelencia [23].

1.4.2.4 Otros modelos

Existen muchos otros modelos de predicción de series temporales, utilizados en la predicción de energías renovables como la eólica y la solar fotovoltaica [12]. Se destacan:

- Modelos grises: los modelos grises se basan en la teoría gris desarrollada por *Deng*. Una de las ventajas de los modelos grises es su fácil aplicación ya que requiere conocer la distribución de los parámetros y no requiere de modelos intermedios complejos. Un número gris es un número cuyo valor exacto se desconoce, pero una serie o rango de números en la que el valor se encuentra, es conocido. Sea x un conjunto cerrado y acotado de números reales. Un número gris, x^- , y límite superior conocido, x^+ . La distribución de información desconocida para x se muestra en la ecuación 1.8.

$$x^\pm = [x^-, x^+] = [t \in X \mid x^- \leq t \leq x^+] \quad (1.8)$$

- Máquina de vectores soporte (SVMs): son un conjunto de algoritmos de aprendizaje supervisado desarrollados por *Vladimir Vapnik* y su equipo en los laboratorios AT&T. Estos métodos están propiamente relacionados con problemas de clasificación y regresión. Dado un conjunto de patrones de entrenamiento se puede etiquetar las clases y entrenar una SVM para construir un modelo que prediga la clase de una nueva muestra. Intuitivamente, una SVM es un modelo que representa a los puntos de muestra en el espacio, y separa las clases por un espacio lo más amplio posible. Cuando las nuevas muestras se ponen en correspondencia con dicho modelo, en función de su proximidad pueden ser clasificadas a una u otra clase. Más formalmente, una SVM construye un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad muy alta (o incluso infinita) que puede ser utilizado en problemas de clasificación o regresión. Una buena separación entre las clases permite una clasificación correcta.
- Modelo de cielo claro (día claro): es un modelo que estima la irradiación global para un día claro para un instante dado. La irradiación de día claro se halla mediante la relación indicada a continuación en la ecuación (1.9).

$$G_{cs} = I_o \cdot \tau_a \quad (1.9)$$

Donde:

I_o es la irradiación extraterrestre (W/m^2).

τ_a es la transmisividad de un día claro.

En el caso de los modelos de predicción de generación solar fotovoltaica se incorpora una nueva relación, equivalente a la anterior, pero que tiene en cuenta la generación (ecuación 1.10):

$$P = P_{cs} \cdot \tau \quad (1.10)$$

Donde:

P es la producción media fotovoltaica.

P_{cs} es la producción equivalente en un día claro (W/m^2).

τ es el índice de atenuación.

La normalización de la potencia o producción mediante el modelo de día claro se debe a que la producción de un día claro es más estacionaria y regular que la producción real. Por ello, se puede incluso en modelos clásicos asumir dicha estacionalidad.

A partir de todo lo anterior, el modelo de día claro se define mediante la ecuación (1.11).

$$P_{cs} = f_{m\acute{a}x}(x, y) \quad (1.11)$$

Donde:

P_{cs} es la producción equivalente en un día claro (W/m^2).

- Modelo de los k vecinos más próximos (k-NN): es una técnica de predicción no lineal de amplia versatilidad y que permite realizar, entre otras, tareas de clasificación, estimación de densidades, aproximación de funciones y predicción de series temporales. El propósito principal de este algoritmo se centra en conocer el comportamiento futuro de los vecinos de un vector, con el fin de predecir el comportamiento de dicho vector.

1.4.2.5 Modelos híbridos

Actualmente, existen modelos que combinan los modelos físicos y los modelos estadísticos, los cuales se conocen como modelos híbridos. El propósito de estos modelos es combinar las ventajas de ambos con el fin de obtener un modelo más preciso y fiable.

Los sistemas neuro-difusos combinan la capacidad de aprendizaje supervisado de una red neuronal con la representación del conocimiento de un sistema de inferencia difusa. Una denominación muy común de este tipo de sistemas es *Adaptive Neuro-Fuzzy Inference Systems* (ANFIS) [12].

Otro caso de modelo híbrido es el uso de redes neuronales optimizadas por medio de algoritmos genéticos, el uso de modelos ARMA con redes neuronales, la unión de varios tipos de redes neuronales, así como la combinación de modelos atmosféricos tales como MM5 para la predicción de radiación y con lógica difusa o redes neuronales para la predicción de potencia.

1.4.3 Modelos de predicción basados en modelos atmosféricos

La modelación numérica meteorológica es el proceso en el cual se obtiene un pronóstico objetivo del estado futuro de la atmósfera mediante la solución de un grupo de ecuaciones que describen la evolución de un grupo de variables (radiación, temperatura, velocidad y dirección del viento, humedad, presión, entre otras) y a su vez el estado de la atmósfera.

Todos los modelos numéricos de la atmósfera se basan en el mismo grupo de ecuaciones que gobierna la atmósfera las cuales son descritas en términos no matemáticos (de conservación de la masa o de continuidad, hidrostática, termodinámica, de estado, de vapor de agua). Los modelos numéricos difieren entre sí en las aproximaciones y suposiciones hechas en la aplicación de estas ecuaciones y en cómo ellas son resueltas para la representación de los diferentes procesos físicos.

Estos modelos a su vez se pueden clasificar según su área de predicción en:

- Modelos atmosféricos globales: son los que ofrecen predicciones meteorológicas de mayor alcance. Estos modelos poseen una resolución del orden de 200 km y su objetivo es identificar el comportamiento general de la atmósfera sobre una zona determinada sin la necesidad de establecer condiciones de contorno en la frontera del dominio. Por tanto, son modelos con capacidad para identificar fenómenos meteorológicos de gran escala.
- Los modelos atmosféricos locales: abarcan en su análisis áreas geográficas por debajo de 200 Km. Estos modelos atmosféricos presentan la desventaja de necesitar, además de las condiciones iniciales, condiciones de contorno en las fronteras del dominio. La ventaja que poseen frente a los modelos atmosféricos globales es el menor esfuerzo computacional en su ejecución.

Dentro de los modelos más utilizados se encuentran:

- Modelo MM5: es un modelo de meso-escala, desarrollado por PSU/NCAR (*Pennsylvania University and National Center for Atmospheric Research*), de área limitada, no hidrostático, el cual tiene un diseño de coordenadas sigma, las cuales están diseñadas para seguir la regularidad del terreno en superficie.
- Modelo WRF-NMM: *Nonhydrostatic Mesoscale Model*, en el fondo responde a una versión mejorada y actualizada del modelo MM5. El WRF es un modelo de meso-escala, desarrollada por NOAA/NCEP (*National Oceanic and Atmospheric/ National Centers for Environmental Prediction*), de área limitada, no hidrostático, pero con una

opción hidrostática. Además, tiene un diseño de coordenadas sigma, las cuales están diseñadas para seguir la regularidad del terreno en superficie [12].

1.5 Consideraciones finales del capítulo

Mediante la revisión bibliográfica, se realiza un recorrido por el estado actual de desarrollo de la energía solar fotovoltaica, así como los métodos de predicción más utilizados a nivel mundial para la predicción de la generación de energía eléctrica en parques solares fotovoltaicos. Se pudo constatar que en los últimos años la inteligencia artificial, específicamente las redes neuronales artificiales, han ganado en popularidad en todas sus variantes. De ellas el perceptrón multicapa es muy popular por tener gran éxito como aproximador universal de funciones y en un gran número de aplicaciones.

CAPÍTULO 2. PROGRAMA PARA LA PREDICCIÓN DE LA GENERACIÓN DE ENERGÍA ELÉCTRICA MEDIANTE REDES NEURONALES ARTIFICIALES

En este capítulo se aborda el tema referente a las redes neuronales artificiales, sus principales características, su estructura y los tipos de entrenamiento que se utilizan. También se aborda el trabajo con la herramienta *nntool* del MATLAB para conformar una red neuronal del tipo MLP que brinde una buena solución al problema planteado.

2.1 Redes neuronales artificiales

Las redes neuronales artificiales consisten en un modelo matemático formado por un gran número de elementos simples, que procesan información mediante su estado dinámico como respuesta a entradas externas. Este tipo de modelo matemático simula el comportamiento del cerebro humano, y es capaz de procesar información, de aprender, y de generalizar igual que las neuronas biológicas [11].

El cerebro biológico está formado por un gran número de elementos interconectados llamados neuronas. Las neuronas son células excitables, que acumulan energía eléctrica en forma de potencial de membrana, para posteriormente liberarla como potencial de acción, y conducir así señales eléctricas. Dichas neuronas (figura 2.1) están formadas por tres elementos principales: las dendritas, el cuerpo celular y el axón.




Figura 2.1. Esquema de los elementos de una neurona biológica [22].

El punto de contacto entre el axón de una neurona y la dendrita de otra neurona se conoce como sinapsis. La sinapsis puede ser eléctrica o química y su función es integrar señales y elaborar respuestas adecuadas, que se traducen en una conducta externa. La función de la red neuronal depende de la estructura de la misma y del tipo de sinapsis que presente.

Las redes neuronales artificiales no llegan a alcanzar la complejidad del cerebro, sin embargo, existen dos grandes similitudes entre las redes neuronales biológicas y las artificiales. Por un lado, las dos son sistemas altamente interconectados, por otro lado, las conexiones entre las diferentes neuronas determinan la función de la red [23].

Aunque las neuronas biológicas son más lentas comparadas con los circuitos electrónicos, el cerebro puede llevar a cabo tareas mucho más rápido que cualquiera computadora convencional, debido a su estructura en paralelo. El concepto moderno de red neuronal artificial comenzó en 1940 con el trabajo de *Warren McCulloch* y *Walter Pitts*, quienes mostraron que las redes neuronales podían llevar a cabo operaciones lógicas y aritméticas. La primera aplicación práctica surgió en 1957 cuando *Frank Rosenblatt* implementó el perceptrón y demostró su utilidad para reconocer patrones. A partir de este momento y en las décadas posteriores, se produjo un gran interés por este campo, desarrollándose nuevos algoritmos de aprendizaje y de entrenamiento, lo que ha facilitado la implementación de aplicaciones en sectores como el aeroespacial, automoción, defensa, electrónica, robótica y medicina [11].

2.2 Elementos de una red neuronal artificial

Las redes neuronales artificiales están formadas principalmente por cuatro elementos: entradas, pesos sinápticos, función de activación y salida [23]. En la figura 2.2 se muestra la estructura de una red neuronal artificial.




Figura 2.2. Estructura de una red neuronal artificial [11].

Las entradas de la red neuronal son señales que pueden proceder del exterior o bien ser la salida de otra neurona. Pueden ser binarias o continuas dependiendo del modelo y la aplicación. Se refiere a entradas binarias cuando están comprendidas entre $[0, +1]$, mientras que las entradas continuas se encuentran $[-1, +1]$.

Los pesos sinápticos son valores numéricos que multiplican a las señales de entrada. Estos valores se ajustan en la fase de aprendizaje de la red y pueden ser positivos, negativos o cero. Si un peso sináptico toma un valor positivo produce una señal excitadora, puesto que cuando el valor positivo se multiplique por la señal de entrada, y se lleve a cabo la sumatoria, tiene influencia positiva. Si por el contrario un peso sináptico toma un valor negativo produce una señal inhibidora por el mismo motivo. Si un peso sináptico toma valor cero quiere decir que la conexión entre esas dos neuronas es inexistente.

La sumatoria de todas las entradas de la neurona, una vez que se multiplican por sus pesos sinápticos, se transforma mediante la función de activación para obtener la salida de la neurona. Las funciones de activación más empleadas son:

- Función de activación lineal: En este tipo de función de transferencia, la salida de la función es directamente proporcional a su entrada (figura 2.3 (a)).
- Función de activación sigmoideal logarítmica: En este tipo de función de transferencia, si los valores de entrada son ligeramente mayores a cero, su salida se aproxima a la unidad, mientras que, si los valores de entrada son ligeramente menores que cero, su salida tiende a cero (figura 2.3 (b)).
- Función de activación sigmoideal tangente hiperbólica: En este tipo de función de transferencia, la salida está comprendida entre 1 y -1 y depende de si la entrada es mayor que cero o menor que cero (figura 2.3 (c)).




Figura 2.3. Funciones de activación. (a) función de activación lineal, (b) función de activación sigmoideal logarítmica y (c) función de activación sigmoideal tangente hiperbólica.

La función de salida se obtiene de la función de activación de la neurona. Esta salida puede utilizarse como salida de la red neuronal, o bien tomarse como entrada de otra neurona.

2.3 Tipos de redes neuronales artificiales más utilizados para la predicción

En el caso específico de la predicción de generación eléctrica en parques solares fotovoltaicos conectados a la red existen varios tipos de redes neuronales que pueden ser utilizados con el propósito de obtener buenos resultados. A continuación, se muestran algunas de estas:

- Red neuronal Perceptrón Multicapa (MLP): es un tipo de red neuronal unidireccional en el que las neuronas están organizadas en capas, de forma que una neurona situada en una capa intermedia sólo puede tener como entradas las salidas de la capa precedente y su salida sirve de entrada para neuronas de la capa siguiente [25].
- Red con retraso de tiempo (FTDNN): son similares a las redes de alimentación hacia delante, excepto que la entrada tiene una línea de retardo asociada. Esto permite que la red tenga una respuesta dinámica finita a los datos de entrada de series de tiempo [22].
- Red neuronal auto-regresiva (NAR): son redes con dinámica recurrente y conexiones de retroalimentación donde la información de salida vuelve a realimentar la red neuronal. Estos modelos están basados en el modelo lineal ARX que es utilizado para la predicción de series temporales, al que incorporan la no linealidad [22].
- Red neuronal auto-regresiva con entradas exógenas (NARX): son redes que combinan la estructura NAR con la FTDNN, es decir, que tienen retardos asociados a variables de entrada y otros asociados a la propia respuesta de la red. Funcionan como un lazo de realimentación, como en las NAR [22].
- Red neuronal unidireccional multicapa generalizada (FFBP): La red neuronal FFBP, comparte las características de la red neuronal MLP, ya que está formada por capas de neuronas con conexiones unidireccionales, pero a diferencia de la red neuronal MLP permite que haya conexiones entre neuronas de capas no consecutivas. Así, para el caso de una red neuronal FFBP con una sola capa oculta, las neuronas de la capa de entrada también se conectan a las neuronas de la capa de salida [12].

La ventaja de la red neuronal FFBP es que, para una misma estructura, necesita menos tiempo en el entrenamiento, al adaptarse más rápidamente los pesos de las conexiones de las neuronas de las primeras capas de la red.

- Red neuronal modular(MNN): Constituye otra variante de la red neuronal MLP. Este tipo de red neuronal se compone de varias redes neuronales multicapa en paralelo, por lo que puede decirse que comparten la capa de entradas y la capa de salidas, pero las capas ocultas son independientes. El valor del vector de salidas de la MNN se obtiene

por combinación lineal de los valores de los vectores de salidas de las sub-redes neuronales [12].

- Red neuronal de función de base radial (RBF): Este tipo de red neuronal tiene un aprendizaje híbrido, es decir, combina el aprendizaje no supervisado con el aprendizaje supervisado. Es una red con tres capas de neuronas: capa de entrada, capa oculta y capa de salida. Además, es una red neuronal unidireccional y sólo se permiten conexiones entre neuronas de capas consecutivas en el orden de entrada a salida. Es muy similar a la red neuronal MLP diferenciándose fundamentalmente en la función de activación de las neuronas de la capa oculta [12].

La ventaja de las RBF es su mayor rapidez en el entrenamiento y la necesidad de un menor número de neuronas para aproximar una función no lineal.

- Redes neuronales *Wavelet*: La arquitectura más sencilla de una red neuronal wavelet consta de una sola entrada y una sola salida. En esta arquitectura la capa oculta está formada por un tipo especial de neurona, las llamadas *wavelons*, cuyos parámetros de entrada están definidos por peso, parámetro de traslación y escalamiento. La salida de la red es una combinación lineal de las funciones *wavelet* de cada *welon* [12].

2.4 Aprendizaje de las redes neuronales artificiales

La característica más importante de las redes neuronales artificiales es el aprendizaje. La finalidad de este proceso es ajustar los pesos sinápticos de las conexiones entre neuronas de forma iterativa para conseguir su objetivo, es decir, para aprender las relaciones presentes entre los vectores de entrada-salida con los que se entrena a la red neuronal y encontrar un patrón común para clasificar los datos de entrada y la respuesta de la red sea la correcta. En las redes neuronales artificiales hay tres tipos de aprendizaje los cuales se explican a continuación:

- **Aprendizaje supervisado:** es el más habitual en aproximación de funciones no lineales con redes neuronales. Es necesario disponer de un conjunto de datos de entrenamiento que contenga tanto el valor del vector de entradas, como el valor del vector de salidas correspondiente a cada valor del vector de entradas. Durante el proceso de aprendizaje, se modifican los pesos sinápticos de las neuronas mediante el error existente entre los valores del vector de salidas de la red neuronal y los valores del vector de salidas esperado [12].

- **Aprendizaje no supervisado:** la red neuronal no recibe ningún valor esperado del vector de salidas, solamente es necesario un conjunto de datos que contenga las entradas donde busca alguna propiedad o correlación para clasificarlos [12].
- **Aprendizaje reforzado:** es un caso especial de aprendizaje supervisado en el que el valor del vector de salidas esperado no es suministrado, únicamente se suministra a la red neuronal la información precisa de si el valor del vector de salidas es igual, o no, al esperado [12].

2.5 Sobreentrenamiento de las redes neuronales artificiales

Cuando la red neuronal artificial se entrena demasiado, es posible que tenga lugar una pérdida de generalización. Esto es debido a que la red predice de manera muy eficaz la respuesta con los datos que son presentados en el entrenamiento, pero no es capaz de generalizar cuando se le presentan datos nuevos, por lo que no aprende correctamente el patrón de entrenamiento.

Existen diferentes métodos para evitar que se produzca sobreentrenamiento a la hora de entrenar la red neuronal. Una de las opciones sería reducir el tamaño de la red neuronal ajustándola en función del objetivo para el que ha sido diseñada. Se debe tener especial cuidado a la hora de utilizar esta técnica ya que si se reduce demasiado el tamaño de la red es posible que no sea capaz de aprender adecuadamente, y la respuesta de la red neuronal no se aproxime al objetivo deseado. Otra de las técnicas utilizadas para evitar el sobreentrenamiento sería la validación cruzada. Este método consiste en dividir el conjunto de datos de entrenamiento en dos. Una de las partes se utiliza para llevar a cabo el entrenamiento propiamente dicho, y la otra parte que se llama conjunto de validación, se utiliza para calcular el error de validación. De esta forma se entrena la red hasta que el error de validación alcance un mínimo (figura 2.4), puesto que después vuelve a aumentar [11].




Figura 2.4. Regla de detención temprana basada en la validación cruzada [11].

2.6 Red neuronal perceptrón multicapa (MLP)

En 1969, *Minsky y Papert*, demuestra que el perceptrón simple y *ADALINE* (tipo de red neuronal artificial desarrollada por el profesor *Bernie Widrow*) no puede resolver problemas no lineales como el XOR. La combinación de varios perceptrones simples podría resolver ciertos problemas no lineales, pero no existía un mecanismo automático para adaptar los pesos de la capa oculta. *Rumelhart* y otros autores, en 1986, presentan la "Regla Delta Generalizada" para adaptar los pesos de propagación de los errores hacia atrás.

Una red neuronal MLP puede tener varias capas ocultas, si bien con una sola capa oculta sería capaz de aproximar, con un error arbitrariamente pequeño, cualquier función continua acotada lineal o no, y con dos capas ocultas cualquier función continua.

El perceptrón multicapa utiliza el algoritmo *backpropagation* (propagación hacia atrás) para llevar a cabo el entrenamiento. Este algoritmo consiste en llevar a cabo el aprendizaje de un conjunto de datos como ejemplo, para obtener la respuesta de la red y comparar el resultado con la salida que se desea obtener. De esta forma se calcula el error en la capa de salida. El error se transmite hacia atrás y pasa por todas las capas intermedias, finalmente se calcula el error en cada una de ellas en función del error total, hasta llegar a la entrada. En este momento se actualizan los valores de los pesos sinápticos de cada capa en función del error generado en dicha capa.

A la hora de diseñar una red neuronal MLP se debe seleccionar el número de capas ocultas y el número de neuronas de cada capa. Cuanto mayor sea el número de capas y de neuronas, mayor es la capacidad de la red neuronal MLP de ajustar cualquier función, pero aumenta el tiempo necesario para entrenarla y se corre el riesgo de sobreentrenar la red.

El principal inconveniente de la red MLP radica en determinar el número de neuronas en la capa oculta ya que no existe un método exacto para lograrlo. Existen algunos métodos que se

pueden ser usados como punto de partida, pero se recomienda utilizar la técnica de prueba y error donde se realiza varios entrenamientos para diferentes cantidades de neuronas en la capa oculta y se elige la que ofrezca los mejores resultados.

2.7 Metodología general para el desarrollo de modelos de predicción

A la hora de desarrollar y evaluar cualquier modelo de predicción se deben seguir una serie de pasos comunes. Estos pasos se describen brevemente a continuación:

- **Planteamiento inicial:** se trata de establecer los objetivos que persigue el modelo de predicción. Para esto hay que ver qué tipo de predicciones son las que más se adaptan a las necesidades actuales, para lo cual es necesario consultar la máxima bibliografía disponible que se relacione con el campo estudiado.
- **Recopilación de datos:** es preciso obtener los datos históricos de las variables de interés, entre las cuales, debe aparecer la variable que el modelo tiene la finalidad de predecir, ya que es la que permite desarrollar y evaluar el modelo.
- **Pre-procesado de los datos:** una vez que se dispone de los datos históricos es preciso verificar la validez de dichos datos. Para ello se debe hacer un estudio estadístico minucioso de los mismos, de forma que permita eliminar los *outliers* presentes en la serie temporal y determinar cuáles son las variables de mayor peso.
- **Entrenamiento y desarrollo de los modelos de predicción:** esta es la etapa central de todo el proceso. En ella se ajusta el modelo, que fundamentalmente se trata de una serie de relaciones lógicas acompañadas de un sistema de ecuaciones que permiten estimar el valor futuro de la variable que se desea para un horizonte de predicción concreto a partir de las entradas correspondientes. El ajuste del modelo se fundamenta en la optimización de sus diferentes parámetros para reducir al máximo el error de predicción, cuanto más pequeño sea el error más preciso es el modelo, o lo que es lo mismo, más exactas son las relaciones encontradas entre las entradas y la variable de salida.
- **Evaluación de los modelos de predicción:** A la hora de elegir, desarrollar o comparar modelos de predicción es preciso que sean evaluados. Para ello hay que utilizar una serie de criterios que permitan calcular la adecuación de las predicciones a la realidad. Obviamente dicha evaluación debe realizarse sobre una serie de datos históricos diferentes a los utilizados en el desarrollo del modelo

- **Aplicación del modelo:** una vez finalizado todo el proceso de desarrollo, el modelo puede ser aplicado a una instalación a tiempo real para obtener las predicciones deseadas.

2.8 Diseño e implementación de la red neuronal artificial en MATLAB mediante la herramienta nntool

En la figura 2.5 se muestra un resumen del procedimiento a seguir para realizar el diseño e implementación de la red neuronal artificial.




Figura 2.5. Procedimiento a seguir para lograr el diseño e implementación de la red neuronal.

2.8.1 Elección del modelo de la red neuronal artificial

El perceptrón multicapa que se diseña está formado por tres capas: capa de entrada, capa oculta y capa de salida. Por lo tanto, se puede afirmar que el diseño implementado tiene topología multicapa. Se elige un modelo con una sola capa oculta puesto que salvo casos que

presenten gran complejidad, no se justifica el uso de dos capas ocultas. El costo computacional de la topología con dos capas ocultas es mucho mayor que con una sola capa oculta y además no se mejoran los resultados.

A la hora de elegir un algoritmo de entrenamiento, hay que tener en cuenta que el perceptrón multicapa se trata de una red *feed-forward backpropagation*, por lo tanto, se debe escoger un algoritmo de entrenamiento del tipo *backpropagation*. De todos los algoritmos disponibles, el algoritmo de *Levenberg-Marquardt* es el más rápido, además de ser altamente recomendable para llevar a cabo un aprendizaje de tipo supervisado [25].

El algoritmo de *Levenberg-Marquardt* es en realidad una combinación de dos métodos de minimización: el método del gradiente descendiente y el método de Gauss-Newton.

En el método del gradiente descendiente, la suma de los errores cuadráticos se reduce mediante la actualización de los parámetros en dirección de la mayor reducción del valor de los mínimos cuadrados. En el método de Gauss-Newton, la suma de los errores cuadráticos se reduce al asumir la función de mínimos cuadrados es localmente cuadrática, y encontrar el mínimo de la función cuadrática.

El método de *Levenberg-Marquardt* actúa más como un método de gradiente descendiente cuando los parámetros están lejos de su valor óptimo, y actúa más como el método de Gauss-Newton cuando los parámetros están cerca de su valor óptimo [2].

2.8.2 Selección de las variables de entrada y salida

Se debe aclarar que los datos que se utilizan corresponden a mediciones de las variables radiación solar, temperatura ambiente, temperatura de los módulos solares y potencia generada, que se toman en intervalos de tiempo de cinco minutos durante el año 2016 y 2017 en el parque solar fotovoltaico de Cruces en la provincia de Cienfuegos.

A la hora de escoger las variables de entrada, se deben tener en cuenta los factores que más influyen en la producción de energía solar fotovoltaica. La temperatura es un factor que afecta directamente a la potencia que entregan los módulos fotovoltaicos, por lo que resulta adecuado que forme parte de las entradas de la red. Por último, la radiación es un factor clave para la generación fotovoltaica, por lo que es altamente recomendable que forme parte de las entradas de la red. Por tanto, la topología de entradas de la red neuronal es de tres entradas: radiación solar, temperatura ambiente y temperatura de los módulos fotovoltaicos.

El propósito principal es la predicción de la potencia generada por el parque solar fotovoltaico, por lo que se toma dicha variable como salida de la red neuronal artificial.

La figura 2.6 muestra un resumen de las variables de entrada y salida que conforman la red neuronal artificial.




Figura 2.6. Configuración de la red neuronal artificial.

2.8.3 Formación de los conjuntos de aprendizaje, test y validación

La red neuronal artificial creada, se entrena con datos correspondientes a cuatro meses característicos del año que pertenecen al periodo de verano e invierno.

Primeramente, se dividen los patrones en dos grupos: el primero de estos grupos corresponde a los meses de enero, mayo, julio y octubre; y el segundo grupo corresponde a una semana al azar del propio mes o del mes siguiente.

El primer grupo se introduce en MATLAB para el entrenamiento de la red neuronal artificial. MATLAB de manera interna divide aleatoriamente estos patrones, y conforma los conjuntos de aprendizaje (70%), de test (15%) y de validación (15%) de los datos. De esta forma, se procede al entrenamiento de la red mediante los ejemplos del conjunto de aprendizaje, mientras que se comprueba esporádicamente su desempeño mediante los datos de validación hasta alcanzar la generalización. Mediante el conjunto de test, se comprueba de manera independiente el estado de la red.

En este caso, además, se realiza la predicción de los días correspondientes al segundo grupo, y se comprueba el comportamiento del MLP en este sentido a través de la comparación con las mediciones de dicho grupo que no formaron parte del entrenamiento.

La base de datos que se toma para el entrenamiento cuenta con mediciones de las variables ya mencionadas con anterioridad, desde junio del 2016 hasta julio del 2017.

En el caso del primer mes característico se utilizan para el entrenamiento de la red los datos correspondientes al mes de enero de 2017 y para validar la red se utilizan datos de las variables de entrada correspondientes a la primera semana del mes de febrero de ese mismo año (31 de enero – 6 de febrero).

Para el segundo caso se utilizan para el entrenamiento de la red los datos correspondientes al mes de mayo de 2017 y para validar la red se utilizan datos de las variables de entrada correspondientes a la primera semana del mes de junio (31 de mayo – 6 de junio).

Para el tercer caso se utilizan en el entrenamiento de la red los datos correspondientes al mes de julio sin incluir la semana del 21 al 27 de julio y parte del mes de agosto de 2016. Para validar la red se utilizan datos de las variables de entrada correspondientes a la tercera semana del mes de julio de 2016 (21 de julio – 27 de julio).

Para el cuarto caso se utilizan para el entrenamiento los datos correspondientes al mes de octubre del 2016 y para validar la red se utilizan los datos de las variables de entrada correspondientes a la primera semana del mes de noviembre de 2016 (1 de noviembre - 7 de noviembre).

De esta forma se puede comprobar la capacidad de aprendizaje de la RNA, así como su desempeño en la predicción de la potencia eléctrica generada por la instalación fotovoltaica en un período de tiempo futuro que no forma parte del entrenamiento.

2.8.4 Pre-procesamiento de los datos

Para una correcta implementación de la red neuronal, es necesario estandarizar los valores de los vectores de entrada. Se debe partir de la premisa de que pequeños cambios en la entrada dan lugar a pequeños cambios en la salida. Si se cumple esto, se consigue mejorar considerablemente el entrenamiento de la red neuronal, con lo que se obtienen mejores resultados en las predicciones. Todos los datos deben estar dentro del intervalo $[-1,1]$ o bien $[0,1]$, por lo que se deben utilizar técnicas para conseguir estos valores.

Una de las técnicas que se utilizan se conoce como técnica de los “máximos”. Con este método se debe buscar el máximo del vector de datos a evaluar. Una vez hallado el valor máximo, se divide cada uno de los datos del vector entre este valor, obteniéndose un nuevo vector estandarizado en el que todas las muestras se encuentran dentro del rango $[0,1]$ puesto que todos los datos del vector original son positivos.

Otro método se conoce como normalización MIN-MAX. Para los datos de las variables que se analiza se utiliza la ecuación 2.1. Este método garantiza una normalización en el rango $[0,1]$.

$$X(normalizado)_i^j = \frac{x_i^j - \min(j)}{\max(j) - \min(j)} \quad (2.1)$$

Donde:

x_i^j : valor i-ésimo de la variable j.

$\min(j)$: mínimo valor que toma la variable j.

$\max(j)$: máximo valor que toma la variable j.

El método que se utiliza en este trabajo consiste en determinar la media y la desviación estándar de cada vector que forma las variables de entrada y de salida y luego aplicar la ecuación (2.2).

$$a' = \frac{a - V_{media}}{V_{std}} \quad (2.2)$$

Donde:

a: es el valor de la variable de entrada o salida.

V_{media} y V_{std} : son los valores de la media y la desviación estándar del vector de entrada o salida.

Si el resultado anterior es menor que cero se aplica la ecuación (2.3).

$$a'' = \frac{a' * (-1)}{m} \quad (2.3)$$

Donde:

m: es el menor valor de los datos que componen el vector analizado.

Si el resultado de la expresión (2.2) es mayor que cero, se aplica entonces la ecuación (2.4).

$$a'' = \frac{a' * 1}{n} \quad (2.4)$$

Donde:

n: es el mayor valor de los datos que componen el vector analizado.

Este método se recomienda en la bibliografía consultada [23] y garantiza que los valores de entrada y salida queden estandarizados en el intervalo [-1,1]. Además, al trabajar con parámetros estadísticos se obtiene mayor calidad en este proceso.

2.8.5 Entrenamiento de la red

El software MATLAB le brinda al usuario dos formas distintas de poder crear el perceptrón multicapa. Una posibilidad de implementar la RNA lo constituye la programación de *scripts*. Además, mediante la herramienta de la librería de redes neuronales artificiales *nntool* (figura 2.7). En el presente trabajo se utiliza la segunda opción para poder observar minuciosamente el desarrollo del proceso.




Figura 2.7. Creación del perceptrón multicapa.

Para la creación de la red neuronal artificial del tipo MLP, se tienen en cuenta los parámetros siguientes:

- *Network type: Feed-forward backpropagation.* En este caso se trata de una red neuronal artificial del tipo perceptrón multicapa que utiliza el método de propagación de errores hacia atrás.
- *Input data:* En este campo se seleccionan las variables de entrada que se emplean posteriormente en el entrenamiento de la red (*data_train*).
- *Target data:* En este campo se selecciona la variable de salida que se emplea posteriormente en el entrenamiento de la red (*gen_train*).
- *Training function:* TRAINLM. Se trata del algoritmo de entrenamiento de *Levenberg-Marquardt* [20] [21]. Este algoritmo requiere un gran uso de memoria, pero se trata del algoritmo más rápido para entrenar redes neuronales artificiales del tipo *feed-forward*. Además, posee excelentes propiedades de convergencia y robustez por lo que se ha convertido en uno de los algoritmos más utilizados actualmente.
- *Adaption learning function:* LEARNGDM. Se trata de la función de aprendizaje de los pesos, la cual utiliza el gradiente descendente con *momentum* lo que acelera la convergencia de los pesos.

- *Performance function*: MSE. Se trata de la función error cuadrático medio entre la salida de la red y la salida deseada.
- *Number of layers*: Es el número de capas de la red. Normalmente, con utilizar dos capas es suficiente (una capa oculta y una de salida) para llevar a cabo la gran mayoría de las tareas. En este caso se eligen dos capas, la primera de ellas corresponde a la capa oculta y la segunda a la capa de salida.

Los parámetros para finalizar la configuración de la red son:

- *Properties for layer 1*: Se lleva a cabo una comparación de los resultados de las pruebas y se varía el número de neuronas en la capa oculta. Se prueba desde una neurona en la capa oculta hasta 12 neuronas ofreciendo los mejores resultados con nueve neuronas. La función de transferencia utilizada es la sigmoideal tangente hiperbólica (*tansig*).
- *Properties for layer 2*: En la capa de salida no se puede elegir el número de neuronas, por lo que solamente se debe escoger el tipo de función de transferencia. Debido a las características de respuesta de la red, se elige una función de activación sigmoideal tangente hiperbólica (*tansig*).

Una vez diseñada la red neuronal artificial, se lleva a cabo su entrenamiento. Se deben confirmar los datos de las entradas y las salidas (objetivos) de la red. Además, se pueden fijar ciertos parámetros referentes al algoritmo de entrenamiento de *Levenberg-Marquardt*, los cuales se muestran a continuación:

- El número máximo de iteraciones (*epochs*) que tienen lugar, por defecto son 1000.
- El tiempo (*time*) que puede durar el entrenamiento de la red, por defecto es infinito.
- El máximo error permitido (*goal*) para finalizar el entrenamiento, por defecto fijado en cero, aunque resulta difícil alcanzar este valor.
- El gradiente mínimo (*min_grad*), representa el valor mínimo que debe alcanzar el gradiente para detener el entrenamiento, por defecto 10^{-7} .
- El número máximo de iteraciones (*max_fail*) en los que no disminuye el error de validación, por defecto es seis. Al alcanzar este valor se detiene el entrenamiento de la red.

2.8.6 Resultados del entrenamiento

Al finalizar el proceso de edición de estos parámetros, se puede comenzar el entrenamiento de la red. En este momento aparece una interfaz que muestra información acerca del estado del entrenamiento de la red neuronal artificial. En la figura 2.8 se muestra dicha interfaz.




Figura 2.8. Interfaz del entrenamiento de la red neuronal artificial.

En la figura 2.8 se puede observar la forma en que varían los diferentes parámetros durante el entrenamiento de la red para nueve neuronas en la capa oculta ya que como se menciona con anterioridad brinda los mejores resultados en el entrenamiento. Como se puede observar, el entrenamiento concluye debido a que transcurren seis épocas en las que el error de validación no disminuye, y se da por finalizado este proceso. Una vez finalizado el entrenamiento, hay disponibles varias gráficas que permiten observar el resultado del mismo. En la figura 2.9 se muestra el comportamiento del error cuadrático medio (MSE) en función del número de iteraciones llevadas a cabo durante el entrenamiento. En este caso la red finaliza el entrenamiento después de 24 iteraciones, con un valor del MSE de 0,0058173 que resulta

bastante pequeño. Este error se obtiene del proceso de validación que se realiza en el propio entrenamiento con el 15% de los datos y de forma aleatoria. Al ser pequeño el error se puede asegurar que la red neuronal generaliza de forma correcta los pesos sinápticos de las neuronas que conforman la misma, al menos si no ocurre un sobreentrenamiento, por lo que se hace necesario realizar una validación con datos históricos que la red no conoce.




Figura 2.9. Comportamiento del error cuadrático medio (MSE).

En la figura 2.10 se puede observar la recta de regresión lineal de los vectores de entrada con respecto a las salidas durante el proceso de entrenamiento, validación y de prueba. La regresión lineal es un modelo matemático utilizado para aproximar la relación de dependencia entre dos valores, en este caso, la entrada y la salida. Cuanto más próximo a uno sea el coeficiente de correlación R , mayor es la dependencia entre la salida y las variables de entrada de la red neuronal.




Figura 2.10. Gráficos de regresión lineal.

2.9 Consideraciones finales del capítulo

A partir del análisis realizado en el presente capítulo se decide utilizar una red neuronal artificial del tipo *feed-forward backpropagation* para realizar la predicción de la generación de energía eléctrica en el parque solar fotovoltaico de Cruces en la provincia de Cienfuegos. La red neuronal desarrollada utiliza como variables de entrada las mediciones de radiación solar, temperatura ambiente y temperatura de los módulos fotovoltaicos en dicho parque y tiene como objetivo la predicción de valores futuros de la variable de salida (potencia generada). Para esto se ensayan diferentes arquitecturas de red y finalmente se concluye que la arquitectura de red con tres entradas, nueve neuronas en la capa oculta y una salida es la que mejores resultados ofrece.

CAPÍTULO 3. RESULTADOS DE LAS PREDICCIONES REALIZADAS

En este capítulo se realiza una pequeña descripción del parque solar fotovoltaico que se analiza, así como los resultados que se obtienen mediante la simulación de la red neuronal artificial. Dicha red ha sido previamente entrenada con los datos correspondientes a cuatro épocas distintas del año y para evaluar su desempeño se utilizan los datos de las variables de entrada de cuatro semanas al azar que no forman parte del conjunto de entrenamiento. De esta forma se puede realizar una comparación entre los valores de generación real y las predicciones realizadas por la red neuronal para un horizonte de tiempo futuro.

3.1 Descripción del parque solar fotovoltaico analizado

El parque solar fotovoltaico de Cruces, en la provincia de Cienfuegos, se encuentra situado aproximadamente en los 22° de latitud norte y 80° de longitud oeste, y posee una potencia nominal de 3,00 MW. Con un costo de inversión de 9 586 000 CUC y una superficie ocupada de $61\,200\text{ m}^2$, fue puesto en marcha el 28 de febrero del año 2015 (figura 3.1).



Figura 3.1. Vista aérea del parque solar fotovoltaico de Cruces.

Este parque solar fotovoltaico cuenta con un total de 1200 mesas dispuestas en 76 filas, divididas en tres inversores. Los paneles fotovoltaicos utilizados son de silicio monocristalino, modelo DSM-250, con una potencia pico de 250 W_p y un voltaje en vacío de $37,7\text{ V}$. La estación ambiental de este parque cuenta con un pirómetro, un barómetro, un higrómetro y termómetros tanto ambiental, como en los paneles fotovoltaicos.

3.2 Resultados obtenidos para el período de tiempo analizado

Una vez entrenada la red neuronal artificial, se analiza su funcionamiento frente a datos que no forman parte del conjunto de entrenamiento, para ver la capacidad de generalización que adquiere la red neuronal artificial.

Para realizar la prueba se escogen cuatro conjuntos de datos, cada uno de siete días y en períodos diferentes del año lo que indica una predicción a largo plazo. Como se explica anteriormente los conjuntos de datos de prueba están repartidos de la siguiente manera:

- 31 de enero al 6 de febrero del 2017.
- 31 de mayo al 7 de junio del 2017.
- 21 al 27 de julio del 2016.
- 1 al 7 de noviembre del 2016.

En las figuras 3.2, 3.3, 3.4 y 3.5 se muestran los gráficos de comparación entre la generación de energía eléctrica real y la predicción realizada por la red neuronal artificial. Estas figuras corresponden a las semanas escogidas para realizar la validación.

Como se puede observar existe una buena correspondencia entre el gráfico de generación real (color azul) y el gráfico de la predicción (color naranja) para todos los días analizados en las diferentes épocas del año, lo que demuestra que la predicción realizada fue buena.




Figura 3.2. Comparación entre la potencia predicha y la generada para la semana comprendida entre el 31 de enero y el 6 de febrero.




Figura 3.3. Comparación entre la potencia predicha y la potencia real para la semana comprendida entre el 31 de mayo y el 6 de junio.




Figura 3.4. Comparación entre la potencia predicha y la potencia real para la semana comprendida entre el 21 y el 27 de julio.




Figura 3.5. Comparación entre la potencia predicha y la potencia real para la semana comprendida entre el 1 y el 7 de noviembre.

Además, se puede decir que en todos los casos las predicciones que realiza la red neuronal artificial son acertadas a pesar de que la variable radiación solar (variable de mayor peso) presenta una alta variabilidad en algunos instantes de tiempo producto del efecto de la nubosidad que incide sobre el parque solar fotovoltaico. Esto provoca una alta variabilidad de la potencia generada por la instalación fotovoltaica, lo que implica una mayor incertidumbre en la predicción.

También se puede analizar el comportamiento de los promedios de generación real y simulada en las cuatro semanas escogidas para la validación (figuras 3.6, 3.7, 3.8 y 3.9).

Como se puede observar en estas figuras, existe una gran similitud entre el promedio de generación real y el promedio de generación predicha, lo que demuestra nuevamente la efectividad de la red neuronal artificial en la predicción de la potencia de salida del parque solar fotovoltaico que se analiza.




Figura 3.6. Promedios de generación real y simulada en la semana comprendida entre el 31 de enero y el 6 de febrero.




Figura 3.7. Promedios de generación real y simulada en la semana comprendida entre el 1 de mayo y el 6 de junio.




Figura 3.8. Promedios de generación real y simulada en la semana comprendida entre el 21 y el 27 de julio.




Figura 3.9. Promedios de generación real y simulada en la semana comprendida entre el 1 y el 7 de noviembre.

Para determinar la calidad de la predicción realizada debe determinarse el error de la predicción, en la literatura especializada se muestran varios criterios para determinar dicho error. Sin embargo, muchos trabajos recomiendan que se utilice como criterio de evaluación del error el MAE (*Mean Absolute Error*), el cual se determina según la ecuación (3.1):

$$MAE = \frac{1}{N} \sum_{i=1}^N |A_i - F_i| \quad (3.1)$$

Donde:

N : número total de datos del conjunto de predicciones.

A_i : valores reales de la variable.

F_i : valores de la variable obtenidos mediante la predicción.

Dicho error se determina para las cuatro semanas analizadas y para cada uno de los días. Los resultados que se obtienen se muestran en la tabla 3.1.

Tabla 3.1. Valores del error medio absoluto para cada día analizado.

Valores del MAE en (MW)	Día de la semana							MAE promedio
	día 1	día 2	día 3	día 4	día 5	día 6	día 7	Semana
(31 de enero - 6 de febrero)	0,0712	0,0681	0,0818	0,0483	0,0654	0,0749	0,0954	0,0721
(1 de junio - 7 de junio)	0,0591	0,0593	0,0342	0,0380	0,0434	0,0569	0,0504	0,0487
(21 de julio - 27 de julio)	0,0580	0,0579	0,0454	0,0454	0,0507	0,0492	0,0519	0,0512
(1 de noviembre - 7 de noviembre)	0,0521	0,0972	0,0652	0,0666	0,0804	0,0575	0,0875	0,080

Según se observa en la tabla anterior los valores en MW del MAE para cada uno de los días son pequeños, lo que demuestra que la predicción realizada para las cuatro semanas escogidas es acertada. Debe aclararse que en las semanas de junio y julio los errores de predicción son menores debido a que la radiación solar en este período de tiempo presenta un comportamiento más estable y por tanto resulta más fácil de predecir.

Es posible realizar una comparación de los resultados que se proporciona la red neuronal MLP con otros modelos de predicción para comprobar su efectividad. En este caso se utiliza una red neuronal del tipo NARX (con tres entradas, tres neuronas en la capa oculta y una salida), con los mismos criterios en el entrenamiento que se utilizan para el MLP, y con la predicción de una serie de tiempo, en este caso un modelo ARIMA. En el anexo I se observan las gráficas de comparación de potencia generada real (color azul) con respecto a la potencia predicha (color naranja) por la red neuronal NARX. En el anexo II se observa las gráficas promedio de

generación real y predicha para las semanas analizadas que se obtienen por la red neuronal NARX. Los resultados de la potencia predicha por el modelo ARIMA para cada uno de los días correspondiente a las cuatro semanas que se analizan, se muestra en el anexo III. La comparación de los valores del MAE de los tres modelos para cada día de la semana y el promedio semanal para los cuatros semanas analizadas se muestran en la tabla 3.2.

Tabla 3.2. Valores del error medio absoluto para cada día analizado.

Valores del MAE en (MW)	Día de la semana							MAE promedio		Tipo de método
	día 1	día 2	día 3	día 4	día 5	día 6	día 7	MW	%	
MAE para la semana (31de enero - 6 de febrero)	0,0712	0,0681	0,0818	0,0483	0,0654	0,0749	0,0954	0,0721	3,26	MLP
	0,0516	0,0515	0,0540	0,0484	0,0495	0,0629	0,0586	0,0537	2,43	NARX
	0,1033	0,1011	0,1135	0,0764	0,0538	0,1041	0,1237	0,0965	4,37	ARIMA
MAE para la semana (31 de mayo - 7 de junio)	0,0592	0,0561	0,0342	0,0380	0,0434	0,0569	0,0504	0,0483	2,13	MLP
	0,0576	0,0668	0,0389	0,0452	0,0487	0,0598	0,0635	0,0543	2,39	NARX
	0,0832	0,0789	0,0344	0,027	0,0591	0,0569	0,0711	0,0585	2,58	ARIMA
MAE para la semana (21 de julio - 27 de julio)	0,0580	0,0579	0,0454	0,0454	0,0507	0,0492	0,0519	0,0512	2,42	MLP
	0,0611	0,0644	0,0525	0,0494	0,0559	0,0550	0,0510	0,0556	2,62	NARX
	0,0742	0,0945	0,0611	0,0615	0,1011	0,0810	0,0879	0,0801	3,78	ARIMA
MAE para la semana (1 de noviembre - 7 de noviembre)	0,0521	0,0972	0,0652	0,0666	0,0804	0,0575	0,0875	0,0723	3,36	MLP
	0,0589	0,0694	0,0547	0,0522	0,0580	0,0598	0,0714	0,0606	2,82	NARX
	0,0577	0,1465	0,0988	0,0950	0,1117	0,1028	0,1455	0,108	5,02	ARIMA

La figura 3.10 muestra de forma gráfica el comportamiento del error medio absoluto (MAE) para cada uno de los días correspondientes a las semanas que se analizan expresados en MW.




Figura 3.10. Comportamiento del MAE para los días correspondientes a las semanas analizadas.

Los mejores resultados para los tres modelos se obtienen en las semanas de junio y julio debido a que estos meses corresponden a la estación de verano donde la cobertura de nubes presenta un comportamiento más estable, al igual que la radiación incidente sobre las células fotovoltaicas por lo que la predicción se hace más fácil por parte de la red neuronal artificial. Al comparar los resultados obtenidos se puede concluir que los modelos basados en redes neuronales ofrecen mejores resultados que el modelo ARIMA. Por otro lado, al comparar la red neuronal MLP con la NARX, se puede ver que la red MLP ofrece los mejores resultados en las semanas de junio y julio donde la cobertura de nubes es más estable. Sin embargo, en las semanas de febrero y noviembre, los errores de predicción de la red NARX son más pequeños que los errores de la red MLP, aunque estos últimos presentan valores aceptables y se encuentran muy cercanos a los errores de la red NARX.

Es necesario aclarar que la formulación matemática de la red neuronal NARX está basada en series de tiempo por lo que se recomienda su uso en series que presenten variaciones constantes de sus parámetros de entrada.

En las figuras 3.11, 3.12, 3.13 y 3.14 se muestra una comparación de los resultados que se obtienen por los tres métodos (MLP, NARX, ARIMA) con los valores de generación real, para

el caso de un horizonte de predicción a corto plazo (en este caso 24 horas), correspondientes al primer día de cada una de las semanas escogidas para la validación.




Figura 3.11. Comparación entre la potencia predicha y la potencia real para el 31 de enero.




Figura 3.12. Comparación entre la potencia predicha y la potencia real para el 31 de mayo.




Figura 3.13. Comparación entre la potencia predicha y la potencia real para el 21 de julio.




Figura 3.14. Comparación entre la potencia predicha y la potencia real para el 1 de noviembre.

Como se observa en las figuras la predicción que se realiza por los tres modelos son correctas, aunque el modelo ARIMA (color carmelita claro) ofrece los resultados más alejados de la realidad, mientras que los modelos de redes neuronales (color azul y rojo) ofrecen los mejores resultados comparados con la potencia real generada (color verde).

Para un mejor análisis se calcula el error absoluto medio (MAE) para las 24 horas de predicción y para cada uno de los modelos que se analizan. En la tabla 3.3 se ofrecen los resultados.

Tabla 3.3. Valores del error medio absoluto para cada día analizado.

Día	Valores del MAE		Método de predicción	Día	Valores del MAE		Método de predicción
	MW	%			MW	%	
Enero 31	0,0691	3,13	MLP	Julio 21	0,0560	2,64	MLP
	0,0581	2,62	NARX		0,0591	2,79	NARX
	0,103	4,66	ARIMA		0,0742	3,5	ARIMA
Mayo 31	0,0547	2,41	MLP	Noviembre 1	0,0491	2,28	MLP
	0,0564	2,49	NARX		0,0554	2,58	NARX
	0,0832	3,66	ARIMA		0,0577	2,68	ARIMA

Como se observa el error en la predicción disminuye para horizontes de tiempo más pequeños, esto confirma lo que se plantea en la bibliografía [8, 9, 12, 17, 20, 21] donde se recomienda el uso de predicciones a corto plazo.

Además, se observa que los modelos que se basan en redes neuronales artificiales ofrecen nuevamente los mejores resultados. En este caso, excepto para el 31 de enero, en los demás días que se analizan los menores errores de predicción se logran con la red neuronal MLP lo que demuestra su efectividad en la predicción de la generación fotovoltaica para un horizonte a corto plazo.

3.3 Consideraciones finales del capítulo

A partir de datos históricos que no forman parte del entrenamiento, se realiza la validación de la red neuronal artificial del tipo MLP para comprobar el nivel de generalización que alcanza la

misma. Para una predicción a corto y largo plazo existe una buena correspondencia entre la potencia real y el gráfico de predicción. Los errores medios absolutos que se calculan en todos los casos son pequeños, lo que demuestran la versatilidad de la red neuronal artificial. En comparación con otros modelos, los resultados obtenidos son mejores que los aportados por el modelo ARIMA y aunque la predicción realizada por la red neuronal artificial del tipo NARX supera en algunos puntos a los de la red MLP, este último tipo de red neuronal mantiene un promedio de errores aceptable en todos los casos y de forma general presenta un comportamiento más favorable en los aspectos de costo computacional y rapidez en el entrenamiento, además no se necesita un gran conocimiento para su uso.

CONCLUSIONES

Los resultados de este trabajo permiten arribar a las conclusiones siguientes:

- Se describen los diferentes métodos que se utilizan para la predicción de la generación de energía eléctrica en parques solares fotovoltaicos mediante la consulta realizada a la bibliografía internacional relacionada con el tema. El análisis que se realiza muestra que la mayoría de los trabajos recomiendan el uso de las redes neuronales artificiales para realizar este tipo de estudio, principalmente las redes del tipo MLP por ser consideradas aproximadores universales de funciones.
- Se diseña una red neuronal artificial del tipo (*Feed-forward backpropagation*) con una capa oculta, mediante la herramienta *nntool* del software MATLAB. Dicha red utiliza como variables de entrada las mediciones históricas de la radiación solar, la temperatura ambiente y la temperatura en los módulos fotovoltaicos y como variable de salida la potencia generada en la instalación fotovoltaica en diferentes épocas del año.
- Con los datos históricos disponibles en el parque solar fotovoltaico de Cruces, se entrena la red neuronal artificial que se crea, obteniéndose los mejores resultados para una arquitectura de red 3-9-1 (tres entradas, nueve neuronas en la capa oculta y una salida).
- La red neuronal artificial MLP que se crea presenta un comportamiento favorable en todos los casos que se analizan en cuanto al tiempo requerido para el entrenamiento, la cantidad de iteraciones, los requerimientos computacionales y el comportamiento del error medio cuadrático.
- A partir de datos históricos de las variables entrada que no forman parte del entrenamiento, se evalúa el comportamiento y el nivel de generalización alcanzado por la red neuronal artificial para cuatro épocas del año diferentes, obteniéndose en todos los casos buenos resultados, con pequeños valores del error de predicción tanto para horizontes de predicción de corto plazo y de largo plazo.
- Se comparan los valores reales de generación de energía eléctrica en la instalación fotovoltaica con las predicciones realizadas por diferentes métodos (MPL, NARX, ARIMA) para horizontes de tiempo futuros y en todos los casos se observa una buena

CONCLUSIONES

similitud. Sin embargo, de forma general la red neuronal MLP muestra mejores resultados y un comportamiento más favorable, lo que demuestra la calidad y efectividad de este método de predicción.

RECOMENDACIONES

- Continuar la validación de la red neuronal artificial con datos pertenecientes a otros parques solares fotovoltaicos del país.
- Incorporar al trabajo otras técnicas de inteligencia artificial como algoritmos genéticos y lógica difusa, para combinarlas con las redes neuronales artificiales y lograr predicciones más exactas y de mayor calidad.
- Aplicar este método para predecir la generación de energía eléctrica con otras fuentes de energía renovable, como la energía eólica.

BIBLIOGRAFÍA

- [1] O. V. Aldoshina and D. V. Tai, "Evaluation and prediction of solar radiation for energy management based on neural networks," *Journal of Physics*, 2017.
- [2] L. F. C. Amagua, "Estimación de la potencia producida por módulos fotovoltaicos en base a redes neuronales artificiales y comparación con metodología basada en regresiones múltiples," Tesis de fin de año, Facultad de Ingeniería Eléctrica y Electrónica, Escuela Politécnica Nacional, Quito, 2016.
- [3] D. M. Bote, "Contribución a la integración de sistemas fotovoltaicos conectados a la red eléctrica: recurso solar y predicción de generación," Tesis Doctoral, Departamento de Electrónica Física, Escuela Técnica Superior de Ingenieros de Telecomunicación, Madrid, 2014.
- [4] Y. Li, Y. Su, and L. J. Shu, "An ARMAX Model for Forecasting the Power Output of a Grid Connected Photovoltaic System," *Renewable Energy*, vol. 66, pp. 78-89, 2014.
- [5] O. Karner, "ARIMA representation for daily solar irradiance and surface air temperature time series," *Journal of Atmospheric and Solar-Terrestrial Physics*, vol. 71, pp. 841-847, 2009.
- [6] Z. Li, S. M. M. Rahman, R. Vega, and B. Dong, "A hierarchical approach using machine methods in solar photovoltaic energy production forecasting," *Energies*, vol. 9, 2016.
- [7] A. Mellit, A. M. Pavan, and V. Lughi, *Short-term forecasting of power production in a large-scale photovoltaic plant* vol. 105, 2014.
- [8] R. Mellit, I. Koprinska, and V. G. Agelidis, "Univariate and multivariate methods for very short-term solar photovoltaic power forecasting," *Energy Conversion and Management*, vol. 121, pp. 280-390, 2016.
- [9] A. Rashkovska, J. Novljan, M. Smolnikar, M. Mohorcic, and C. Fortuna, "Online short-term forecasting of photovoltaic energy production," presented at the IEEE Power and Society Innovative Smart Grid Technologies Conference, 2015.
- [10] W. Xiao, G. Nazario, H. Wu, H. Zhang, and F. Cheng, *A neural network based computational model to predict the output power of different types of photovoltaic cells*. vol. 12, septiembre 2017.
- [11] F. R. Paler, "Predicción mediante redes neuronales de la producción de energía de un parque fotovoltaico," Tesis de fin de grado, Departamento de Electrónica y Telecomunicaciones, Universidad de Alcalá, 2017.
- [12] A. M. Jimenes., "Modelos de predicción a corto plazo de la generación eléctrica en instalaciones fotovoltaicas.," Tesis doctoral, Ingeniería Eléctrica., Escuela Técnica Superior de Ingeniería Industrial, Universidad de Rioja., 2014.
- [13] G. Alba, "Fundamentos de energía solar. Radiación solar ", Instituto de Física. Facultad de Ingeniería, Universidad de la República.
- [14] *Modeling Solar Radiation at the Earth's Surface: Recent Advances*, 2008.
- [15] C. E. Moratiel, "Estudio de viabilidad sobre la previsión horaria de la producción de energía solar fotovoltaica mediante técnicas de redes neuronales," Proyecto Fin de Carrera, Ingeniería Industrial, Escuela Técnica Superior de Ingeniería, Universidad Pontificia Comillas, Madrid, junio de 2009.
- [16] J. S. Cigales, "Estudio y simulación de un sistema fotovoltaico de conexión a la red," Tesis de fin de año, Departamento de Ingeniería Industrial, Universidad Politécnica de Valencia 2014.

- [17] M. S. T. Olarte, "Nuevos modelos de predicción a corto plazo de la generación eléctrica en plantas basadas en energía solar fotovoltaica," Tesis doctoral, Ingeniería Eléctrica, Universidad de la Rioja, 2017.
- [18] C. Mörklen, "Uncertainty in win energy forecasting," Universidad de Cork, Irlanda, 2004.
- [19] J. Usaola, O. Ravelo, G. González, F. Soto, M. C. Dávila, and B. Díaz-Guerra, "Benefits for Wind Energy in Electricity Markets from Using Short Term Wind Power Prediction Tools; A Simulation Study," *Wind Engineering*, vol. 28, pp. 119-127, 2004/01/01 2004.
- [20] A. F. R. Granda, "Predicción de la potencia activa a corto plaso de un parque fotovoltaico utilizando una red neuronal artificial," Tesis de fin de año, Facultad de Ingeniería Eléctrica y Electrónica, Escuela Politécnica Nacional, Quito, mayo 2017.
- [21] A. Muñoz-Jiménez, P. Zorzano-Santamaría, L. A. Fernández-Jiménes, E. Zorzano-Alba, A. Yanguas-Peña, and E. García-Garrido, "Modelos de Predicción a corto plazo para sistemas fotovoltaicos," *Conferencia Hispano-Lusa de Ingeniería Eléctrica*, julio 2009.
- [22] M. d. C. M. I. R. Martinez, "Sistemas Inteligentes para el ajuste de Modelos Hidrológicos. Aplicación al Río Paraná," Tesis Doctoral, Departamento de Matemática Aplicada y Ciencias de la Computación, Universidad de Cantabria, 2013.
- [23] B. M. d. Brio and A. S. Molina, *Redes neuronales y Sistemas difusos*, Segunda edición ed., marzo 2001.
- [24] L. Llano, G. Zapata, and D. Ovalle, "Sistema de Inferencia Difuso para Identificar Eventos de Falla en Tiempo Real " *Avances en Sistemas e Informatica*, vol. 4, septiembre de 2007.
- [25] MATLAB, *Neural Network Toolbox, User's Guide*, 2014.

ANEXOS

Anexo I: Resultados de la predicción realizada por la red neuronal NARX




Figura 1. Gráfico de comparación entre la generación real y la generación predicha por la red NARX para la primera semana de febrero de 2017.




Figura 2. Gráfico de comparación entre la generación real y la generación predicha por la red NARX para la semana del 31 de mayo al 6 de julio.




Figura 3. Gráfico de comparación entre la generación real y la generación predicha por la red NARX para la semana del 21 de julio al 27 de julio.




Figura 4. Gráfico de comparación entre la generación real y la generación predicha por la red NARX para la semana del 1 de noviembre al 7 de noviembre.

Anexo II: Resultados de la predicción promedio realizada por la red neuronal NARX




Figura 1. Gráfico de comparación entre el promedio de generación real y el promedio de generación predicha por la red NARX, para la primera semana de febrero de 2017.




Figura 2. Gráfico de comparación entre el promedio de generación real y el promedio de generación predicha por la red NARX, para la semana comprendida del 31 de mayo al 6 de junio.




Figura 3. Gráfico de comparación entre el promedio de generación real y el promedio de generación predicha por la red NARX, para la semana comprendida del 21 de julio al 27 de julio.




Figura 4. Gráfico de comparación entre el promedio de generación real y el promedio de generación predicha por la red NARX, para la semana comprendida del 1 de noviembre al 7 de noviembre.


Anexo III: Resultados de la predicción realizada por el modelo ARIMA

Figura 1. Gráfico de comparación entre la generación real y la generación predicha por el modelo ARIMA para la semana del 31 de enero al 6 de febrero.




Figura 2. Gráfico de comparación entre la generación real y la generación predicha por el modelo ARIMA para la semana del 31 de mayo al 6 de junio.




Figura 3. Gráfico de comparación entre la generación real y la generación predicha por el modelo ARIMA para la semana del 21 de julio al 27 de julio.




Figura 4. Gráfico de comparación entre la generación real y la generación predicha por el modelo ARIMA para la semana del 1 de noviembre al 7 de noviembre.