



Universidad Michoacana de San Nicolás de Hidalgo

FACULTAD DE INGENIERÍA ELÉCTRICA
DIVISIÓN DE ESTUDIOS DE POSGRADO

**PREDICCIÓN Y CARACTERIZACIÓN DE LA OPERACIÓN
DE SISTEMAS DE GENERACIÓN
FOTOVOLTAICOS UTILIZANDO REDES NEURONALES
ARTIFICIALES**

TESIS

Que para obtener el grado de:

MAESTRO EN CIENCIAS EN INGENIERÍA ELÉCTRICA

Presenta

José Luis Sánchez García

Directora de Tesis

Doctora en Sistemas eléctricos de potencia

Elisa Espinosa Juárez

MORELIA, MICHOACÁN

MARZO DE 2016.





Predicción y Caracterización de la Operación de Sistemas de Generación Fotovoltaicos Utilizando Redes Neuronales Artificiales.

Los Miembros del Jurado de Examen de Grado aprueban la Tesis de Maestría en Ciencias en Ingeniería Eléctrica de *José Luis Sánchez García*

Dr. Juan José Flores Romero
Presidente del Jurado

Dra. Flisa Espinosa Juárez
Director de Tesis

Dr. Claudio Rubén Fuerte Esquivel
Vocal

Dr. Antonio Ramos Paz
Vocal

Antonio Ramos Paz

Dr. Domingo Torres Lucio
Revisor Externo (Instituto Tecnológico de Morelia)

Dr. Félix Calderón Solorio
*Jefe de la División de Estudios de Posgrado
de la Facultad de Ingeniería Eléctrica. UMSNH
(Por reconocimiento de firmas).*

UNIVERSIDAD MICHOACANA DE SAN NICOLÁS DE HIDALGO
Marzo 2016

*A mi padre, porque su cariño y enseñanzas me siguen impulsando a alcanzar
mis metas.*

*A mi madre, porque su fortaleza y cariño me han sacado adelante en
momentos de flaqueza.*

A mis hermanos, ya que sin ellos la vida seria mucho mas aburrida.

A la pequeña Marissa, tú llegada puso aún mas alegría en mi vida.

A Blanquita, te convertiste en una mas de nuestra familia.

Agradecimientos

- A mi familia por su apoyo y amor incondicionales.
- A mi asesora, la Dra. Elisa Espinosa, por su apoyo y paciencia durante la realización de esta tesis.
- Al Dr. Juan Flores, por sus consejos durante la realización de esta tesis.
- Al personal de la División de Estudios de Posgrado de la Facultad de Ingeniería Eléctrica por el apoyo prestado durante estos dos años.
- Al M.C. José Luis Guillen, por que sin su apoyo, este proyecto no habría sido posible.
- Al Consejo Nacional de Ciencia y Tecnología, por la beca otorgada para la realización de esta tesis.
- A mis amigos, que nunca dejaron que tuviera un día aburrido de trabajo.

Lista de Publicaciones

J.L. Sánchez-García, E. Espinosa-Juárez, R. Tapia-Juárez. Photovoltaic Panel Characterization by Using Artificial Neural Networks and Comparison with Classical Models. *International Autumn Meeting on Power, Electronics and Computing*, 2015

Resumen

En esta tesis, se propone una metodología, basada en la aplicación de redes neuronales artificiales, para caracterizar sistemas de generación fotovoltaicos (SGFV). La primera etapa de este trabajo consiste en el desarrollo de un sistema predictor de las condiciones meteorológicas que influyen directamente en la conversión de la energía solar en energía eléctrica. El objetivo del desarrollo de este sistema predictor, es tener la capacidad de pronosticar la potencia de salida del SGFV para un instante en el futuro el cual puede ser a corto, mediano y largo plazo.

La segunda etapa de la caracterización es la de la unidad de generación, consiste en la caracterización del arreglo fotovoltaico, es decir, el conjunto de paneles fotovoltaicos, así como los inversores que hacen la interconexión a la red eléctrica. Una vez caracterizado el arreglo fotovoltaico, se podrá obtener la potencia de salida del mismo, utilizando únicamente como entradas la temperatura de la celda y la irradiancia incidente sobre los paneles fotovoltaicos.

La metodología propuesta para ambas etapas se basa en la aplicación de redes neuronales artificiales (RNA). Se optó por esta técnica para poder obtener una metodología generalizada, es decir, aplicable en cualquier SGFV de cualquier capacidad, sin la necesidad de obtener modelos matemáticos complejos, siempre y cuando se cuente con los datos de entrenamiento necesarios para las RNA. Para validar la metodología propuesta, se utilizaron mediciones obtenidas de uno de los tres arreglos del SGFV instalados en la División de Estudios de Posgrado de la Facultad de Ingeniería Eléctrica de la Universidad Michoacana de San Nicolás de Hidalgo (UMSNH). Como datos de entrenamiento de la primera etapa, se utilizaron mediciones reales obtenidas con una estación meteorológica Vantage Pro 2 Davis, instalada en el campus de Ciudad Universitaria de la UMSNH, en la ciudad de Morelia Michoacán, que fueron tomadas desde el año 2013 a la fecha; para la segunda etapa, además de las mediciones de la estación meteorológica, fueron utilizadas mediciones tomadas del inversor del SGFV en el entrenamiento.

Palabras clave: *Redes neuronales, paneles fotovoltaicos, predicción, clima, caracterización.*

Abstract

In this thesis, a methodology based on artificial neural networks to characterize photovoltaic generation systems (PVGS) is proposed. The first stage in the characterization of a PVGS consists of the development of a meteorological forecasting system. The objective behind the development of this system is to be able to forecast the power output of a PVGS in short, medium and long term.

The second stage of the characterization of the PVGS consist of the characterization of the photovoltaic array, in other words, a group of photovoltaic panels and the power converters that make the interconnection with the power grid. Once the PV array is characterized, the power output of this array can be obtained, using as inputs the cell temperature and the solar irradiation.

The methodology proposed for both stages is based in the implementation of artificial neural networks (ANN). The reason for using ANN is due to a generalized methodology of characterization of PVGS is wanted, a methodology that can be applied to any PVGS, no matter the capacity, the location where it is installed, without the need of obtaining complex mathematical models, as long as the proper training data set is available. To validate this work one of three PV arrays of the PVGS installed in the Graduated Studies Division of the Electrical Engineering School of the UMSNH were characterized and then, the results obtained by the ANN's were compared with real measurements taken from the inverter. As training data set for the first stage, meteorological measurements of the past three years were used, this measurements were obtained using a meteorological station Vantage Pro 2 Davis, installed on campus of the UMSNH.

The validation of the methodology proposed was made by comparing the results of the same, against real measurements.

Contenido

Lista de Publicaciones	VII
Resumen	IX
Abstract	XI
Contenido	XIII
Lista de Figuras	XVII
Lista de Tablas	XIX
Lista de Símbolos	XXI
1. Introducción	1
1.1. Revisión del estado del arte	3
1.2. Objetivos de la Tesis	6
1.2.1. Objetivo general	6
1.2.2. Objetivos particulares	7
1.3. Justificación	7
1.4. Metodología	8
1.5. Descripción de Capítulos	8
2. Predicción de Condiciones Meteorológicas Mediante RNA	11
2.1. Generalidades de redes neuronales artificiales	12
2.1.1. Estructura de las RNA	12
2.2. Entrenamiento de las RNA	14
2.2.1. Algoritmos de entrenamiento	15
2.2.1.1. Gradiente Conjugado con reinicio de <i>Powell-Beale</i> (<i>traincgb</i>)	15
2.2.1.2. Gradiente Descendiente con tasa de aprendizaje momentáneo y adaptivo (<i>traingdx</i>)	16
2.2.1.3. Levenberg Marquardt (<i>trainlm</i>)	16
2.3. Evaluación del desempeño de las RNA	17
2.4. Condiciones meteorológicas relevantes para un SGFV	18
2.4.1. Sensación Térmica	19
2.4.2. Densidad del Aire	19
2.4.3. Presión Atmosférica	20
2.4.4. Humedad	21
2.4.5. Índice THSW (Temperatura, humedad, irradiación solar, velocidad del viento)	22

2.4.6.	Velocidad del viento	24
2.5.	Horizontes de predicción	24
2.5.1.	Predicción a largo plazo (h pasos hacia adelante)	25
2.5.2.	Predicción a mediano plazo (1 día en adelante)	25
2.5.3.	Predicción a corto plazo (1 hora en adelante)	26
2.6.	Predicción de condiciones meteorológicas que influyen en la operación de un SGFV	26
2.6.1.	Predicción de la temperatura	27
2.6.1.1.	Predicción a largo plazo	27
2.6.1.1.1.	RNA para la sensación térmica	28
2.6.1.1.2.	RNA para la densidad del aire	29
2.6.1.1.3.	RNA para la presión atmosférica	33
2.6.1.1.4.	RNA para la humedad	33
2.6.1.1.5.	RNA para el índice THSW	35
2.6.1.1.6.	RNA para la velocidad del viento	35
2.6.1.1.7.	RNA para la temperatura ambiente	39
2.6.1.2.	Predicción a mediano plazo (Un día hacia adelante)	41
2.6.1.3.	Predicción a corto plazo (Una hora hacia adelante)	42
2.6.2.	Predicción de la irradiancia	43
2.6.2.1.	Predicción a largo plazo	45
2.6.2.2.	Predicción a mediano plazo (Un día hacia adelante)	46
2.6.2.3.	Predicción a corto plazo (Una hora hacia adelante)	47
2.6.3.	Conversión de la temperatura ambiente a la temperatura de operación del módulo	49
2.7.	Conclusiones del Capítulo	50
3.	Caracterización de Unidades de Generación Fotovoltaicas	53
3.1.	Descripción del SGFV a caracterizar	55
3.2.	Descripción de la RNA propuesta	58
3.2.1.	Entrenamiento de la RNA propuesta	58
3.3.	Validación de la RNA propuesta	61
3.4.	Comparación de la caracterización con RNA's contra modelos clásicos	64
3.4.1.	Modelo de Osterwald	64
3.4.2.	Modelo de Araujo-Green	65
3.4.3.	Modelo de un diodo	66
3.4.4.	Comparación de los modelos	66
3.5.	Caracterización del inversor	69
3.5.1.	Descripción y validación de la RNA propuesta para el inversor	70
3.6.	Conclusiones del capítulo	71
4.	Casos de Estudio	73
4.1.	Predicción de h días en adelante	73
4.2.	Predicción con 24 horas de adelanto	78
4.3.	Predicción con 1 hora de adelanto	80
4.4.	Conclusiones del capítulo	85

5. Conclusiones y Trabajos Futuros	89
5.1. Trabajos futuros	91
Apéndice A. Extracto de Datos Tomados con la Estación Meteorológica	93
Referencias	95

Lista de Figuras

2.1. Caracterización de un SGFV	12
2.2. Sensación térmica presente durante los días 3 al 5 de Febrero del 2015 en la ciudad de Morelia Michoacán	20
2.3. Comportamiento de la densidad del aire durante el periodo del 3 al 5 de Febrero del 2015	21
2.4. Comportamiento de la presión atmosférica durante los días 3,4 y 5 de Febrero del 2015	22
2.5. Comportamiento de la humedad en los días 3, 4 y 5 de Febrero del 2015 en la ciudad de Morelia Michoacán	23
2.6. Comportamiento del indice THSW durante en los días 3,4 y 5 de Febrero del 2015 en Morelia Michoacán	23
2.7. Comportamiento de la velocidad del viento en la ciudad de Morelia los dias 3, 4 y 5 de Febrero del 2015	24
2.8. Diagrama esquemático del sistema de predicción	28
2.9. Sensación térmica predicha por la RNA	31
2.10. Densidad del aire medida y la obtenida con la RNA	32
2.11. Presión atmosférica predicha por la RNA	34
2.12. Humedad medida y la obtenida con la RNA	35
2.13. indice THSW medido y el obtenido con la RNA	36
2.14. Velocidad del viento entregada por la RNA con diferente número de neuronas durante el entrenamiento con el algoritmo <i>traingdx</i>	37
2.15. Velocidad del viento predicha contra la medida	38
2.16. Arquitectura de la RNA propuesta para la predicción de T_a	39
2.17. Temperatura ambiente medida y la obtenida con la RNA	40
2.18. Temperatura predicha contra la medida en la estación meteorológica	41
2.19. Diagrama de flujo para la predicción de T_a con el método de una hora hacia adelante	44
2.20. Temperatura predicha con el método de una hora hacia adelante contra la temperatura real adelante	45
2.21. Irradiancia medida y la obtenida con la RNA del método de h pasos	47
2.22. Irradiancia medida y la obtenida con la RNA utilizando la técnica de un paso hacia adelante	48

2.23. Irradiancia medida y la obtenida con la RNA utilizando la técnica de una hora en adelanto	48
3.1. Hoja de datos del panel S72PC-300	54
3.2. Interfaz Webbox	56
3.3. Diagrama esquemático del SGFV	57
3.4. Mapa de irradiación solar diaria en México	57
3.5. Estructura de la RNA usada para la caracterización del arreglo fotovoltaico	59
3.6. Gráfica de los datos utilizados para el entrenamiento	60
3.7. Histograma de error de la RNA propuesta	61
3.8. Gráfica P_{cd} vs G del entrenamiento de la RNA con la arquitectura propuesta y la implementación de la misma	62
3.9. Gráfica P_{cd} vs G del entrenamiento de la RNA con una arquitectura que de prioridad al desempeño durante el entrenamiento	62
3.10. Potencia real del 9 de Febrero contra la obtenida con la RNA	63
3.11. Potencia real del 10 de Febrero contra la obtenida con la RNA	64
3.12. Potencia real del 11 de Febrero contra la obtenida con la RNA	65
3.13. Potencia de salida para el panel KC200GT usando los modelos clásicos y las RNA's	67
3.14. Potencia de salida para el panel MSX-60 usando los modelos clásicos y las RNA's	69
3.15. Potencia de CA real comparada con la obtenida por la RNA	71
4.1. Condiciones meteorológicas pronosticadas para el día 13 de Febrero	74
4.2. Potencia de CA real y pronosticada para el 13 de Febrero	75
4.3. Condiciones meteorológicas pronosticadas para el día 14 de Febrero	75
4.4. Potencia de CA real y pronosticada para el 14 de Febrero	76
4.5. Condiciones meteorológicas pronosticadas para el día 15 de Febrero	77
4.6. Potencia de CA real y pronosticada para el 15 de Febrero	77
4.7. Condiciones meteorológicas pronosticadas para el día 13 de Febrero	78
4.8. Potencia de CA real y pronosticada para el 13 de Febrero	79
4.9. Condiciones meteorológicas pronosticadas para el día 14 de Febrero	79
4.10. Potencia de CA real y pronosticada para el 14 de Febrero	80
4.11. Condiciones meteorológicas pronosticadas para el día 15 de Febrero	81
4.12. Potencia de CA real y pronosticada para el 14 de Febrero	81
4.13. Condiciones meteorológicas pronosticadas para el día 13 de Febrero	82
4.14. Potencia de CA real y pronosticada para el 13 de Febrero	83
4.15. Condiciones meteorológicas pronosticadas para el día 14 de Febrero	83
4.16. Potencia de CA real y pronosticada para el 14 de Febrero	84
4.17. Condiciones meteorológicas pronosticadas para el día 15 de Febrero	84
4.18. Potencia de CA real y pronosticada para el 15 de Febrero	85
4.19. Irradiancia y Temperatura ambiente pronosticados para los días 2,3 y 4 de Abril del 2016	86
4.20. Potencia de CA para los días 2, 3 y 4 de Abril del 2016	86

Lista de Tablas

2.1. Predicciones y mediciones reales de la sensación térmica para el cálculo del RMSE	30
2.2. RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la sensación térmica	31
2.3. RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la densidad del aire	32
2.4. RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la presión atmosférica	33
2.5. RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la humedad	34
2.6. RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA del índice THSW	36
2.7. RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la velocidad del viento	38
2.8. RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la temperatura	40
2.9. RMSE para la predicción de la temperatura utilizando el método de un día hacia adelante	42
2.10. Rendimiento de los diferentes métodos para predecir temperatura	43
2.11. RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la irradiancia solar	46
2.12. Desempeño de los diferentes métodos para predecir la irradiancia solar	49
3.1. RMSE y tiempo de computo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA que caracteriza el arreglo fotovoltaico	60
3.2. Pseudomediciones para la caracterización de los paneles MSX-60 y KC200GT mediante RNA's	68
3.3. MSE y MAE para los diferentes métodos de modelado empleados en ambos paneles	69
4.1. Tabla comparativa del RMSE para G , T_a y P_{ca} usando los tres métodos de predicción	82

A.1. Extracto de datos obtenidos con la estación meteorológica <i>Vantage Pro 2</i> . . .	94
---	----

Lista de Símbolos

<i>RNA</i>	Red Neuronal Artificial.
<i>SGFV</i>	Sistema de Generación Fotovoltaico.
<i>STC</i>	<i>Standart Test Conditions.</i> Condiciones de Prueba Estándar.
<i>NOCT</i>	<i>Nominal Operating Cell Temperature.</i> Temperatura Nominal de operación de la Celda.
<i>CD</i>	Corriente Directa.
<i>CA</i>	Corriente Alterna.
<i>G</i>	Irradiancia Solar.
T_a	Temperatura Ambiente.
T_c	Temperatura de Operación de la Celda Fotovoltaica.
<i>W</i>	Watts.
W_p	Watts Pico.
kW_p	Kilowatts Pico.
$^{\circ}C$	Grados Celsius.
<i>m</i>	Metros.
<i>s</i>	Segundos.
W_p	Watts Pico.
<i>ARMA</i>	<i>Auto Regressive Moving Average Model.</i> Modelo Autoregresivo de Media Móvil.
<i>RMSE</i>	<i>Root Mean Square Error.</i> Desviación de la Raíz Cuadrada Media.
<i>MSE</i>	<i>Mean Square Error.</i> Error Medio Cuadrático.
<i>MAE</i>	<i>Mean Absolute Error.</i> Error Medio Absoluto.
<i>CGB</i>	<i>Conjugate Gradient with Powell-Beale Restarts.</i> Gradiente Conjugado con reinicios de Powell-Beale.
<i>LM</i>	Levenberg-Marquardt.
<i>GDX</i>	<i>Gradient Descent with Momentum and Adaptive Learning Rate.</i> Gradiente descendiente con tasa de aprendizaje momentánea y adaptiva.

Capítulo 1

Introducción

Durante mucho tiempo las fuentes primarias de energía utilizadas por el ser humano han sido los combustibles fósiles, los cuales impulsaron en gran medida la revolución industrial. Sin embargo, en la actualidad se presenta el reto de encontrar una nueva fuente primaria de energía, una fuente que sea limpia, renovable y sustentable. Esto debido a dos grandes problemas, el primero, los efectos adversos al planeta relacionados con el uso de estos combustibles, y el segundo, el agotamiento de las reservas mundiales de hidrocarburos. Algunas estimaciones [S. Shafiee09] dicen que las reservas de combustibles fósiles estarán agotadas en los próximos 50 años, mientras que otras [Gluskoter02] dicen que será dentro de 100 a 120 años. A pesar de esto, el hecho es que ninguna de esas dos proyecciones resulta muy alentadora para la comunidad mundial y se deben tomar medidas ante este escenario ya que la demanda de energía no disminuirá, por el contrario, se verá aumentada [Gylfason00].

Una de las principales medidas que se debe de definir es la elección de fuentes renovables de energía, la energía solar representa una buena alternativa, pues proviene de una fuente inagotable de energía limpia y sustentable. Es por esta razón, que en los últimos años, la tecnología relacionada a la generación de energía eléctrica a partir de energía solar ha experimentado avances significativos, haciendo cada vez más eficientes los paneles fotovoltaicos, permitiendo aprovechar de una mejor manera la energía solar. Sin embargo, la integración de unidades de generación fotovoltaica presenta retos complejos a los operadores de la red, esto, debido a la intermitencia de la fuente primaria de energía,

[I. Sansa14], ya que una nube cruzando puede crear una variabilidad de hasta un 80 % en la irradiancia solar recibida por el panel en menos de un segundo [Ogimoto10], lo cual enfatiza la necesidad de una adecuada caracterización de los paneles fotovoltaicos, de manera que el operador pueda predecir la generación de potencia por parte de las unidades de generación fotovoltaica en un periodo de tiempo, lo cual ayudará en la planeación, operación y gestión de la red.

Aunado a esto, la capacidad de poder predecir el recurso solar disponible, con un grado de certidumbre aceptable, resulta de gran importancia hoy en día, por lo que su investigación ha crecido de manera importante en los últimos años. Sumado a la importancia que tiene para el diseño, planeación y operación de las redes, la predicción del recurso solar resulta de interés también para las entidades y participantes de los cada vez más comunes mercados energéticos.

En cuanto a la caracterización de paneles solares han sido reportados diversos métodos desde la aparición de la tecnología fotovoltaica, algunos logrando un alto grado de simplicidad [Osterwald86][G. Araujo82a], pero cuyos resultados presentan diferencias considerables cuando se comparan contra la potencia real medida en los paneles fotovoltaicos modelados; otros enfoques, logran resultados con una precisión aceptable [S. Samkeliso15a], sin embargo, requieren de un complejo modelo matemático, comúnmente obtenido mediante un algoritmo iterativo para calcular los parámetros del panel. Aquí es donde la caracterización mediante red neuronal artificial (RNA) resulta de gran utilidad, pues sin la necesidad de la implementación de ningún tipo de modelo matemático, logra resultados precisos, inclusive a veces mejores que aquellos obtenidos con los modelos matemáticos [G. Almonacid10], esto, sin sacrificar la simplicidad que conlleva el uso de redes neuronales artificiales, las cuales, solamente requiere de un mínimo de información del funcionamiento de los paneles para su entrenamiento.

Así mismo, debido a la variabilidad de la fuente primaria de energía en el proceso de conversión de la energía solar en electricidad, se hace necesario tener una caracterización confiable del panel fotovoltaico. En esta tesis se persigue ese objetivo, se propone una RNA de múltiples entradas y una salida (MISO), la cual tendrá como entradas la irradiancia y la temperatura de operación de la celda fotovoltaica y tendrá como salida la potencia de

entregada por el arreglo fotovoltaico.

Una vez definida la estructura de las RNA para la predicción de las condiciones operativas de los paneles fotovoltaicos (G y Tc), así como una RNA que permita caracterizar de manera confiable y precisa cualquier panel fotovoltaico será posible la predicción de la potencia de salida de un sistema de generación fotovoltaico. En esta tesis se validaron las metodologías desarrolladas con un caso de estudio, el cual se realizó utilizando el sistema de generación fotovoltaico de la División de Estudios de Posgrado de la Facultad de Ingeniería Eléctrica, el cual consta de tres arreglos monofásicos de 12 paneles de 300 Wp (Watts pico) en serie, entregando 3800 Wp por arreglo, se hará un análisis del funcionamiento de las RNA propuestas, comparando los resultados obtenidos, con los que se obtienen con modelos clásicos de paneles fotovoltaicos, así como con las mediciones reales.

1.1. Revisión del estado del arte

Con el auge y la alta penetración de sistemas de generación fotovoltaicos en las redes modernas, la necesidad de una caracterización precisa, confiable y accesible de estos sistemas se ha hecho indispensable. Como se mencionó anteriormente se han realizado diversas propuestas con este objetivo, algunas ofreciendo un alto grado de simplicidad, pero careciendo de precisión y confiabilidad, otros, ofreciendo una precisión adecuada, pero dependientes de un complejo modelo matemático. También se han utilizado técnicas de inteligencia artificial para la caracterización de paneles fotovoltaicos, entre estas técnicas, se encuentran las basadas en RNA's.

En [A. Moreno-Muñoz08] se presenta un modelo multiplicativo autoregresivo de media móvil (ARMA, por si siglas en inglés) para generar un valor instantáneo de la irradiancia global. El conjunto de datos utilizados para la creación de este modelo corresponde a 5 minutos de mediciones de irradiancia global, obtenidos con una estación radiométrica localizada en la ciudad de Cordoba, España. Para el desarrollo de este modelo, se removió la periodicidad anual de los datos, así como la variación estacional de la irradiancia global. La selección del orden del modelo, se hizo considerando siete criterios diferentes, los resultados obtenidos se compararon con mediciones reales.

En [E. Lorenz09] se propone un enfoque para predecir la irradiancia solar de hasta tres días en adelante, utilizando datos del Centro Europeo del Pronóstico del Clima. Este trabajo se centra en la descripción y evaluación del enfoque para la predicción de la irradiancia solar. La predicción de un día en adelante para una sola estación en Alemania muestra una raíz del error medio cuadrático (RMSE, por sus siglas en inglés) relativo de 36 %. Para predicciones regionales, la precisión del pronóstico aumenta mientras menor sea la región de la que se desea hacer la predicción.

En [H. Maimouna13] se hace un análisis a detalle de diferentes métodos de predicción de irradiancia solar, de manera que se puedan observar las carencias y virtudes de los diferentes enfoques. En este trabajo, primero se detallan los enfoques estadísticos y los basados en imágenes satelitales de las masas nubosas, después, se da énfasis a los métodos numéricos para la predicción de la irradiancia solar y por último, se ofrece un panorama de los métodos basados en técnicas de inteligencia artificial.

En [F. Wang12] se presenta una metodología de predicción de irradiancia utilizando RNA's, las cuales, son entrenadas con un vector de mediciones reales, reconstruido mediante técnicas estadísticas. La estructura de este modelo es determinada mediante una validación cruzada, y se utiliza el algoritmo de Levenberg-Marquardt para el entrenamiento de las RNA's. Se realizan simulaciones y se comparan los resultados de este enfoque, con los obtenidos mediante RNA's entrenadas únicamente con mediciones históricas, observándose que el enfoque propuesto, ofrece mejores resultados ante condiciones meteorológicas variables.

En [Naci-Celik11] se hace énfasis en la importancia de conocer la irradiancia solar futura para la operación de una planta de generación fotovoltaica interconectada al sistema, fundamental para los planes de despacho de potencia. Para el entrenamiento de la RNA se utilizó una base de datos de mediciones de irradiancia solar y temperatura del aire correspondiente a 406 días. Al comparar los resultados de la irradiancia solar promedio y la temperatura del aire obtenidos con la RNA contra las mediciones reales, se encontró que en días soleados se tiene una desviación de no más del 2 %, y en días nublados, una desviación no mayor al 4 %.

En [A. Kumar14] se enfatiza en la importancia de la predicción de la radiación

solar incidente sobre el lugar donde se planea la instalación de un sistema de generación fotovoltaica, se hace una revisión de los principales enfoques de predicción utilizando técnicas de redes neuronales artificiales.

En [S. Lineykin12] se hace la estimación del modelo de panel fotovoltaico de cinco parámetros, el cual está basado en el análisis de las características del panel fotovoltaico provistas por el fabricante en la hoja de datos. Este método combina la solución de un sistema de ecuaciones algebraicas con un algoritmo de optimización para la extracción de siete parámetros del circuito equivalente de un diodo del módulo fotovoltaico. Estos parámetros son la corriente fotoeléctrica, la corriente inversa de saturación, el factor de idealidad, las resistencias serie y paralelo y el coeficiente de temperatura de la corriente foto generada.

En [L. Sandrolini10] se propone un procedimiento numérico para la extracción de los parámetros del modelo de panel fotovoltaico de doble diodo. Un algoritmo de optimización de enjambre de partículas es usado para ajustar la característica voltaje-corriente de un panel fotovoltaico a la obtenida experimentalmente. Como no se encontró una solución recurrente en las simulaciones realizadas, principalmente por la naturaleza estocástica del algoritmo de optimización, se emplearon métodos estadísticos en combinación con técnicas de análisis de clúster para obtener los parámetros del panel fotovoltaico. Este enfoque permite obtener un conjunto de parámetros que representan el sistema físico.

En [A. Mellit13] se presenta un enfoque novedoso para modelar un panel fotovoltaico, se proponen dos RNA, la primera se encargará de predecir la potencia de salida de un panel fotovoltaico policristalino de 50 Wp en días soleados, en los cuales, la irradiancia promedio sea igual o mayor a 400 W/m^2 , la segunda se encargará de predecir la potencia de salida del mismo panel, pero en días nublados, con una irradiancia promedio menor a 400 W/m^2 . Ambas redes fueron entrenadas y validadas con mediciones de irradiancia, temperatura del aire, voltaje y corriente del panel, tomadas durante aproximadamente un año. Los resultados obtenidos con ambas RNA fueron comparados con la mediciones de potencia de salida reales, además de diversos modelos implícitos (regresión polinomial, regresión lineal múltiple, modelo analítico y modelo de un diodo), al analizar los resultados, se observa que los obtenidos con las redes neuronales presentan una menor diferencia contra las mediciones

reales.

En [I. Sansa14] se propone una RNA para caracterizar la corriente de operación de un panel fotovoltaico de 120 Wp monocristalino. Este trabajo hace énfasis en las ventajas que ofrece el enfoque basado en RNA para el modelado de paneles fotovoltaicos, ya que es capaz de ofrecer resultados precisos sin necesidad de conocer los componentes internos del sistema, con un esfuerzo computacional menor que el modelo analítico de 5 parámetros clásico de paneles fotovoltaicos. Los resultados obtenidos son validados contra el modelo analítico y contra las mediciones reales, mostrando que la caracterización basado en RNA presenta una menor desviación referente a las mediciones reales.

En [I. Ceylan14] se propone una RNA para calcular la temperatura de operación del panel fotovoltaico, basándose en mediciones de la temperatura del aire y la irradiancia solar, usando estos datos para entrenar la RNA. Se hace un estudio de la potencia de salida y la eficiencia eléctrica basados en la temperatura de operación del panel.

En [S.A. Kalogirou14] se propone una RNA para predecir la potencia de salida de sistemas de generación fotovoltaicos de alto impacto a la red, cuya generación es mayor a 1 MW , en este trabajo, la RNA propuesta fue entrenada con mediciones tomadas durante 226 días, los resultados obtenidos por la red fueron validados con mediciones reales y presentaron una desviación de no más del 5 por ciento respecto a las mediciones reales, probando la robustez de la caracterización mediante RNA de sistemas de generación de alto impacto en la red.

1.2. Objetivos de la Tesis

1.2.1. Objetivo general

Desarrollar e implementar una metodología para la caracterización de sistemas de generación fotovoltaicos, capaz de representar cualquier arreglo del sistema de generación fotovoltaico, bajo cualquier condición de operación, y obteniendo resultados confiables, con la menor cantidad de información previa disponible sobre las condiciones del lugar donde se instalará.

1.2.2. Objetivos particulares

- Desarrollar un sistema predictor de condiciones meteorológicas basado en mediciones que permita estimar la operación de SGFV's.
- Desarrollar una metodología para la caracterización de paneles fotovoltaicos, optimizando la información y recursos disponibles.
- Integración del sistema predictor y la metodología de caracterización de paneles fotovoltaicos, de manera que sea posible predecir la potencia de salida para un SGFV en diferentes ventanas de predicción hacia el futuro, obteniéndose resultados razonablemente precisos.

1.3. Justificación

La energía solar es una de las alternativas de energía limpia con mayor desarrollo hoy en día. La energía proveniente del sol en una hora es suficiente para satisfacer la demanda de la población mundial por todo un año [Corning10]. Los rayos del sol incidentes en la superficie terrestre transmiten luz y calor, la luz es convertida en electricidad en sistemas fotovoltaicos. Los paneles solares consisten en un conjunto de celdas solares, conectadas entre sí en arreglos serie-paralelo, esto para obtener la potencia de salida deseada [Buresch83].

Dado el inminente aumento de la instalación de SGFV, resulta evidente la necesidad del desarrollo de técnicas que permitan el máximo aprovechamiento del recurso solar; técnicas que permitan no solo evaluar el correcto funcionamiento de los sistemas de generación instalados, sino que además permitan analizar su integración a la red eléctrica y la problemática asociada a dicha interacción y la planeación a futuro de la expansión con la creación de nuevos SGFV. Con el desarrollo de técnicas de predicción del recurso solar y caracterización de paneles fotovoltaicos, se pueden lograr estos objetivos, permitiendo a los diseñadores y operadores de las redes eléctricas un mayor grado de certidumbre para la implementación e integración de sistemas de generación que tienen como fuente de energía primaria el sol.

1.4. Metodología

Para lograr los objetivos planteados en esta tesis, se ha seguido la siguiente metodología:

- Revisión de estado del arte en lo relacionado a predicción de condiciones relevantes para la operación de un SGFV y referente a la caracterización de paneles fotovoltaicos, esto con la finalidad de comprender las técnicas y metodologías usadas para este tipo de problemas y obtener el conocimiento necesario para el correcto desarrollo de esta tesis.
- Planteamiento, desarrollo y validación de una técnica de predicción de condiciones meteorológicas basada en RNA's.
- Diseño de una arquitectura apropiada de RNA para la predicción de G y T_a .
- Planteamiento, desarrollo y validación de una metodología de caracterización de paneles fotovoltaicos utilizando RNA's.
- Diseño de una arquitectura apropiada de RNA para la caracterización del arreglo fotovoltaico.
- Implementación y validación del sistema predictor de condiciones meteorológicas y del método de caracterización de paneles fotovoltaicos mediante la realización de casos de estudio en condiciones de operación reales.

1.5. Descripción de Capítulos

En este capítulo se han presentado conceptos preliminares que ayudan a la comprensión de este trabajo. Se hace énfasis, en base a la literatura acerca de la importancia del desarrollo de técnicas que ayuden a optimizar la explotación del recurso solar como fuente primaria en la generación de energía eléctrica, en base a esto, se exponen los objetivos que se esperan lograr con el desarrollo de esta tesis así como la metodología para lograrlos.

En el Capítulo 2 se aborda el tema de la influencia de las condiciones meteorológicas que intervienen en la conversión de la energía solar en energía eléctrica a través de paneles

fotovoltaicos. Se propone una técnica de predicción de estas variables meteorológicas, basada en RNA. Esta técnica es implementada y validada con mediciones reales que se utilizan como caso base.

En el Capítulo 3 se propone un método para la caracterización de paneles fotovoltaicos. Este método es implementado para la caracterización de un arreglo fotovoltaico de 3.8 *kWp*. La metodología propuesta es entonces comparada con las mediciones reales obtenidas de una instalación real.

El Capítulo 4 presenta la unificación de la técnica de predicción y del método de caracterización de paneles fotovoltaicos. Una vez unificados, se presentan casos de estudio en los cuales, mediante una base de datos históricos se predice la potencia de salida y es comparada contra mediciones reales del SGFV instalado en la División de Estudios de Posgrado de la Facultad de Ingeniería Eléctrica de la UMSNH.

Finalmente, en el Capítulo 5 se presentan las conclusiones generales de esta tesis, y se sugieren trabajos futuros, que siguen la misma línea de investigación de esta tesis.

Capítulo 2

Predicción de Condiciones Meteorológicas Mediante RNA

La conversión de energía solar en energía eléctrica es actualmente considerada como una de las tecnologías más prometedoras, en aras de reducir la huella de carbono que la generación de energía eléctrica generada mediante fuentes no renovables deja sobre el planeta, así como reducir el precio de kWh generado mediante recursos renovables. Para cumplir con estos objetivos, los sistemas de generación fotovoltaicos deben de cumplir dos requerimientos. El primero, la relación costo beneficio de la energía generada debe de ser aceptable y el segundo, el rendimiento del sistema de generación debe de ser positivo y mucho mayor a cero, es decir, que la energía generada durante la vida útil de la instalación fotovoltaica debe ser mayor que los insumos de energía durante el ciclo de vida del sistema, dichos insumos incluyen los relacionados a la fabricación de los componentes, la instalación y mantenimiento de la instalación fotovoltaica [M. Hosenuzzaman15].

Considerando lo anterior, se hace necesaria una planificación exhaustiva para instalaciones fotovoltaicas de gran capacidad, mediante la implementación de estudios de viabilidad tanto económicos como operativos. La Figura 2.1 muestra un esquema de lo que se considera en la caracterización de un SGFV. En este capítulo nos enfocaremos en la creación del subsistema de predicción de la irradiación solar y la temperatura




Figura 2.1: Caracterización de un SGFV

2.1. Generalidades de redes neuronales artificiales

Debido a la importancia de cuantificar la potencia que puede generar un panel fotovoltaico, se han realizado diversos estudios en este sentido. La mayoría de ellos se basan en principios físicos con parámetros determinados experimentalmente utilizando la ecuación clásica del circuito equivalente de la unión P-N [G. Tiwari10]. Sin embargo, actualmente se están utilizando técnicas de inteligencia artificial, las cuales son capaces de encontrar correlaciones entre datos diversos y que han mostrado ser útiles en la determinación de parámetros de paneles fotovoltaicos y simulación de sistemas de generación de energía eléctrica a través de fuentes renovables de energía [Jiang05] [Karatepe03]. Una de las características de las técnicas de inteligencia artificial es que son del tipo caja negra y por lo tanto, no se tiene una función explícita de las variables físicas involucradas, pero se tiene una representación adecuada de su interacción [Armas09].

2.1.1. Estructura de las RNA

Una red neuronal consiste en un conjunto de neuronas artificiales interconectadas de una forma concreta. Generalmente los elementos están organizados en grupos llamados capas, las cuales son un conjunto de neuronas cuyas entradas provienen de la misma fuente y cuyas salidas se dirigen al mismo destino. En una red neuronal, se pueden identificar tres tipos de capas: Capas de entrada, salida y ocultas. Las neuronas de la capa de entrada reciben señales desde el entorno; las de salida envían la señal fuera de la red, y las ocultas son aquellas cuyas entradas y salidas se encuentran dentro del sistema. Asociada con cada capa hay una función de salida, que transforma el estado actual de activación en una

señal de salida. Existen cuatro funciones de transferencia típicas que determinan distintos tipos de neuronas: Función escalón, función lineal y mixta, sigmoideal y función gaussiana [I. Basheer00]. Cada conexión entre neuronas tiene un peso asociado, que hace que la red adquiera conocimiento. Se considera que el efecto de cada señal es aditivo, de tal forma que la entrada neta que recibe una neurona es la suma del producto de cada señal individual por el valor de la sinapsis que conecta ambas neuronas y es lo que se conoce como red de propagación. Se utiliza una matriz W con todos los pesos, si w_{ji} es positivo indica que la relación entre las neuronas es excitadora, es decir, siempre que la neurona i esté activada, la neurona j recibirá una señal que tenderá a activarla. Si w_{ji} es negativo, la sinapsis será inhibitoria. La ecuación (2.1) describe matemáticamente lo mencionado anteriormente, donde x representa al vector de entradas así como y al vector de salidas. Finalmente si w_{ji} es 0 se supone que no hay conexión entre ambas. Cuando ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes, la red se describe como de propagación hacia adelante [R. Iyer13].

$$y_j = \sum_i w_{ji} x_i \quad (2.1)$$

Los pesos sinápticos en la matriz W cambian en cada iteración en base a reglas de aprendizaje, en este caso, la regla de Hebb, la cual está basada en la observación de un experimento neurobiológico, el cual estableció que si las neuronas en ambos lados de una sinapsis son activadas repetida y sincronizadamente, la fuerza de la sinapsis aumenta. Matemáticamente, esta regla puede ser definida por la ecuación (2.2).

$$w_{ij}(t+1) = w_{ij}(t) + \eta y_j(t) x_i(t) \quad (2.2)$$

Donde x_i e y_i son las salidas de las neuronas i y j respectivamente, las cuales están conectadas a la sinapsis w_{ij} , y η es la tasa de aprendizaje. Nótese que x_i es la entrada de la sinapsis. Una propiedad importante de esta regla es que la tasa de aprendizaje ocurre localmente, por lo que las modificaciones a los pesos sinápticos dependen únicamente de las dos neuronas conectadas por la sinapsis [Jain96].

Cuando las salidas pueden ser conectadas como entradas de neuronas de niveles previos o del mismo nivel, incluyéndose ellas mismas, la red es de propagación hacia atrás.

Cada neurona tiene una regla de activación, la cual combina las entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función F produce un nuevo estado de activación en una neurona a partir del estado que existía y la combinación de las entradas con los pesos de las conexiones. Esa F es denominada función de activación, y las salidas se obtienen en una neurona para las diferentes formas de F [K. Mehrotra96].

2.2. Entrenamiento de las RNA

El objetivo del entrenamiento de una RNA es conseguir que una aplicación determinada, para un conjunto de entradas produzca el conjunto de salidas deseadas o mínimamente consistentes. El proceso de entrenamiento consiste en la aplicación secuencial de diferentes conjuntos o vectores de entrada para que se ajusten los pesos de las interconexiones según un procedimiento predeterminado. Durante la sesión de entrenamiento los pesos convergen gradualmente hacia los valores que hacen que cada entrada produzca el vector de salida deseado. [N. Karayiannis97]

Los algoritmos de entrenamiento supervisado requieren el emparejamiento de cada vector de entrada con su correspondiente vector de salida. El entrenamiento consiste en presentar un vector de entrada a la red, calcular la salida de la red, compararla con la salida deseada, y el error o diferencia resultante se utiliza para realimentar la red y cambiar los pesos de acuerdo con un algoritmo que tiende a minimizar el error. Las parejas de vectores del conjunto de entrenamiento se aplican secuencialmente y de forma cíclica. Se calcula el error y el ajuste de los pesos por cada pareja hasta que el error para el conjunto de entrenamiento entero sea un valor pequeño y aceptable. Hay tres formas de llevar a cabo el aprendizaje: 1) aprendizaje por corrección de error: consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseado y los obtenidos en la salida de la red, es decir en función de los errores cometidos a la salida; 2) aprendizaje por refuerzo: es un aprendizaje más lento, durante el aprendizaje no se tiene un ejemplo completo del comportamiento deseado, es decir no se indica la salida exactamente durante el entrenamiento. La función del supervisor durante este aprendizaje es indicar una señal de refuerzo en el caso de que la salida se ajuste a la que deseamos, en función de ello se ajustan

los pesos basándose en un mecanismo de probabilidades; 3) aprendizaje estocástico: consiste en cambiar aleatoriamente los valores de los pesos de las conexiones de la red y evaluar el efecto que se produce a partir del objetivo deseado y de distribuciones de probabilidad [G. Carpenter91].

2.2.1. Algoritmos de entrenamiento

En las RNA's es necesario establecer un algoritmo que sea responsable de actualizar los pesos de cada elemento de la matriz W ya que la salida de la RNA debe tener la tendencia a reducir el error en cada iteración. La inclusión de no linealidades modificarán los vectores originales, generando un nuevo vector de entrada al sistema [G. Towell94]. A continuación, se describen los algoritmos de entrenamiento usados en esta tesis.

2.2.1.1. Gradiente Conjugado con reinicio de *Powell-Beale* (*traincgb*)

El algoritmo *backpropagation* básico ajusta los pesos en la dirección descendente más pronunciada (negativo del gradiente). Esta es la dirección en la cual el desempeño de la función decrece más rápidamente. Sin embargo, si bien la función decrece más rápidamente hacia el negativo del gradiente, esto no significa necesariamente que converja más rápido. En los algoritmos de gradiente conjugado, en lugar de seguir la pendiente descendente del gradiente, se sigue la dirección conjugada de la pendiente del gradiente, lo que provoca que se tenga una convergencia más rápida. En este tipo de algoritmos (de gradiente conjugado), la variación en los pesos sinápticos se ajusta en cada iteración. Para todos los algoritmos de gradiente conjugado, la dirección de la búsqueda es reiniciada periódicamente hacia la dirección negativa del gradiente. El punto de reinicio ocurre cuando el número de iteraciones es igual al número de pesos existente en la red, pero hay otros métodos de reinicio que pueden mejorar la eficiencia del entrenamiento. Uno de ellos es el propuesto en [Beale72], el cual se basó en una versión anterior propuesta en [Powell77]. Para esta técnica, el reinicio ocurrirá si hay muy poca ortogonalidad entre el gradiente actual y el anterior. Esto es comprobado con la siguiente desigualdad:

$$|g_k^T - g_k| \geq 0.2 \|g_k\| \quad (2.3)$$

Donde g_k es el valor actual del gradiente. Si esta condición se cumple, la dirección de la búsqueda se reiniciara al negativo del gradiente.

2.2.1.2. Gradiente Descendiente con tasa de aprendizaje momentáneo y adaptivo (*traingd*)

En algoritmos basados en el criterio del gradiente descendiente, la tasa de aprendizaje se mantiene constante durante el entrenamiento. El desempeño del algoritmo es muy sensible al ajuste correcto de la tasa de aprendizaje. Si la tasa de aprendizaje está ajustada a un nivel muy alto, el algoritmo puede oscilar y convertirse en inestable. Si la tasa de aprendizaje está ajustada a un nivel muy bajo, el algoritmo tardará mucho tiempo en converger. No resulta práctico establecer el ajuste óptimo de la tasa de aprendizaje antes del entrenamiento ya que de hecho, el nivel óptimo de ajuste de la tasa de aprendizaje cambia durante el proceso de entrenamiento [E. Moreira95].

El desempeño del algoritmo de gradiente descendiente puede ser mejorado si se permite que la tasa de aprendizaje cambie libremente durante el proceso de entrenamiento. Una tasa de aprendizaje adaptiva intentara mantener el paso de aprendizaje tan largo como sea posible mientras se mantenga estable. Además, con la propiedad de que el aprendizaje sea momentáneo, se permite que si el nuevo error supera al del instante anterior por encima de una radio predefinido (típicamente 1.04), los nuevos pesos y *bias* asociados a este error son desechados. Si esto sucede, se reduce la tasa de aprendizaje (típicamente multiplicándola por 0.7). En caso de que el nuevo error no supere al anterior, los pesos y *bias* se mantienen y la tasa de aprendizaje se aumenta (típicamente multiplicando por 1.05). Este procedimiento incrementa la tasa de aprendizaje, pero solo si la RNA puede aprender sin un aumento significativo en el error, así, se obtiene un valor para la tasa de aprendizaje cercana a la óptima [Atiya91].

2.2.1.3. Levenberg Marquardt (*trainlm*)

El algoritmo de *Levenberg-Marquardt* se diseñó para resolver problemas de sistemas no lineales sin la necesidad de calcular la matriz Hessiana. Cuando la función de desempeño

tiene la forma de una suma de cuadrados, la matriz Hessiana es aproximada como:

$$H = J^T J \quad (2.4)$$

donde J es la matriz Jacobiana que contiene las primeras derivadas de los errores de la RNA con respecto a los pesos y *bias*. El gradiente puede ser calculado como:

$$g = J^T e \quad (2.5)$$

donde e es el vector de errores de la RNA. El algoritmo *Levenberg-Marquardt* usa la aproximación de la matriz Hessiana de la siguiente forma:

$$X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T e \quad (2.6)$$

cuando el escalar μ es cero, es como si fuera el método de Newton usando la matriz Hessiana aproximada. Cuando μ tiene un valor alto, el método se transforma en el del gradiente descendiente con un tamaño de peso pequeño. El método de Newton es más rápido y más preciso cerca de un error mínimo, así que se busca que el algoritmo cambie al método de Newton lo más pronto posible. Así, el valor μ decrece después de cada paso exitoso (cuando el valor de la función de desempeño decrece) e incrementa solo cuando en un paso el valor de la función de desempeño aumente. De esta manera el valor de la función de desempeño siempre se reducirá en cada iteración del algoritmo [A. Suratgar07].

2.3. Evaluación del desempeño de las RNA

En la creación de cualquier tipo de sistemas predictores, resulta de vital importancia la valoración de su desempeño mediante la utilización de algún tipo de criterio estandarizado. La raíz del error medio cuadrático (RMSE, por sus siglas en inglés) es sin duda uno de los criterios más importantes para evaluar el desempeño de un sistema predictor [Fisher20]. El RMSE, definido por (2.7) mide el promedio de los errores al cuadrado, es decir, el cuadrado de la diferencia entre los valores reales de la variable que se desea evaluar contra las predicciones de los valores de la misma [Bermejo01], es por lo anterior, que resulta una excelente herramienta para evaluar el desempeño tanto del sistema predictor de

condiciones meteorológicas como de la caracterización del arreglo fotovoltaico presentados en esta tesis.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2} \quad (2.7)$$

Donde Y es un vector de valores observados o valores reales y \hat{Y} es un vector de n predicciones.

2.4. Condiciones meteorológicas relevantes para un SGFV

La irradiancia solar así como la temperatura de operación de las celdas fotovoltaicas son parámetros de suma importancia en la investigación de la energía solar, sin embargo no siempre están disponibles, o la información disponible no es suficiente para poder realizar un estudio de factibilidad adecuado. Es por eso que resulta crucial el poder predecir estas variables que afectan directamente la generación de energía eléctrica de un SGFV utilizando varias variables meteorológicas. Dependiendo de la técnica utilizada para la predicción se pueden utilizar todas, o algunas de las siguientes variables: horas sol, temperatura ambiente máxima, humedad relativa, latitud, longitud, día del año, año, irradiancia diaria en condiciones de cielo despejado, cobertura nubosa total, temperatura, índice de claridad, sensación térmica, altitud, temperatura promedio, nubosidad promedio, velocidad del viento promedio, presión atmosférica, irradiancia media difusa, irradiancia extraterrestre, evaporación, temperatura el suelo, etc [A. K. Yadav14]. La disponibilidad de estos datos puede variar, dependiendo del tipo de estación meteorológica instalada en el sitio, es por eso, que en este trabajo se buscó crear una metodología de predicción que pudiera funcionar con los datos más fácilmente obtenibles. A continuación se listan las variables meteorológicas que de acuerdo a lo reportado acerca de este tópico son más relevantes, obtenibles con la estación meteorológica disponible y que son consideradas en este trabajo para la predicción de la temperatura de operación del panel (T_c) y la irradiancia (G) para la realización de este trabajo.

En el Apéndice A se muestra un extracto de los datos obtenidos por la estación meteorológica *Vantage Pro 2*. Estos datos corresponden al día 5 del mes de mar-

zo del 2015. Cabe mencionar que datos de estaciones meteorológicas en distintos puntos de México y otros países se pueden obtener en diversos sitios web, tales como: <https://www.wunderground.com>

2.4.1. Sensación Térmica

La sensación térmica es el decremento en la temperatura del aire percibida por una superficie debido al flujo de aire. Una superficie pierde calor por conducción, convección y radiación. La tasa de convección depende de la diferencia de temperatura entre la superficie y sus alrededores. Mientras la convección desde una superficie caliente, calienta el aire alrededor de ella, una capa aislante de aire caliente se forma presionándose contra la superficie. El aire que fluye interfiere con esta capa, permitiendo que el aire frío remplace al aire caliente contra la superficie, mientras más elevada sea la velocidad del viento, más rápidamente se enfría la superficie [Xydis14].

La variable sensación térmica fue elegida como parámetro en el sistema predictor, debido a la relación que existe entre la temperatura de las celdas fotovoltaicas, y la potencia de salida, además, de que presenta un comportamiento sin tantos cambios bruscos, lo que permitirá que las RNA encuentren una correlación entre los datos. La Figura 2.2 muestra la sensación térmica presente durante 72 horas seguidas (3 al 5 de Febrero del 2015) en la ciudad de Morelia Michoacán, obtenidas de la estación meteorológica instalada en el campus de la UMSNH. Se observó que si bien no presentó una periodicidad exacta, si presentó un patrón, lo que hará más fácil su predicción.

2.4.2. Densidad del Aire

La densidad del aire es la masa por unidad de volumen de la atmósfera de la tierra. Tanto la densidad del aire, como la presión, disminuyen conforme aumenta la altitud. También cambia con variaciones en la temperatura y la humedad. A nivel del mar y a 15 °C, el aire tiene una densidad de aproximadamente 1.225 Kg/m^3 . La influencia de la densidad del aire sobre la potencia generada por un arreglo fotovoltaico va de la mano con la masa del aire [Y. Li15]. La masa del aire se define como la cantidad de masa de la atmósfera terrestre que los rayos del sol tienen que atravesar hasta llegar a incidir sobre el arreglo



Figura 2.2: Sensación térmica presente durante los días 3 al 5 de Febrero del 2015 en la ciudad de Morelia Michoacán

fotovoltaico, esto es, porque mientras más alta sea la densidad del aire, más partículas capaces de absorber y dispersar los fotones de luz estarán presentes en la masa del aire, lo que provocará que los fotones incidentes en la superficie del arreglo fotovoltaico sean menos, influyendo en la potencia de salida generada. La Figura 2.3 muestra el comportamiento de la densidad del aire en el periodo que abarca del día 3 al 5 de Febrero del año 2015 en la ciudad de Morelia Michoacán. Se observó que si bien no presentó una periodicidad exacta, si presentó un patrón, lo que hará mas fácil su predicción.

2.4.3. Presión Atmosférica

La presión atmosférica es la presión que ejerce la atmósfera que rodea la tierra sobre todos los objetos que se hallan en contacto con ella. La presión atmosférica cambia con la altitud, a mayor altitud menor presión atmosférica, un aumento en altitud de 1 000 m representa una disminución de presión atmosférica de aproximadamente 100 *hPa*. Relacionar de manera directa la presión atmosférica y la generación fotovoltaica resulta complicado, pero una relación aceptada es la concerniente a la atenuación de los rayos solares causada por la absorción, primero por el ozono de la atmósfera externa, que recorta la radiación del espectro ultravioleta, y posteriormente por el vapor de agua y el dióxido de carbono




Figura 2.4: Comportamiento de la presión atmosférica durante los días 3,4 y 5 de Febrero del 2015

pasar. Puede ser refractada, reflejada o difractada. Estos efectos disminuyen el nivel de recepción de irradiancia en la celda [S. Mekhilef14]. La Figura 2.5 muestra el comportamiento de la humedad en los días 3, 4 y 5 de Febrero del 2015 en la ciudad de Morelia Michoacán, observándose una vez mas la presencia de un patrón, lo que hará mas fácil su predicción.

2.4.5. Índice THSW (Temperatura, humedad, irradiación solar, velocidad del viento)

El índice THSW utiliza la humedad y la temperatura para calcular una temperatura aparente, tal como el índice de calor, pero además incorpora los efectos de calentamiento causados por la irradiación solar y los efectos de enfriamiento debidos al viento [L. Cortez12]. Con este índice se puede obtener una mejor correlación entre las condiciones meteorológicas mencionadas y la temperatura de operación de la celda [Steadman79]. La Figura 2.6 muestra el índice THSW presente en los días 3, 4 y 5 de Febrero del 2015 en la ciudad de Morelia Michoacán.




Figura 2.5: Comportamiento de la humedad en los días 3, 4 y 5 de Febrero del 2015 en la ciudad de Morelia Michoacán

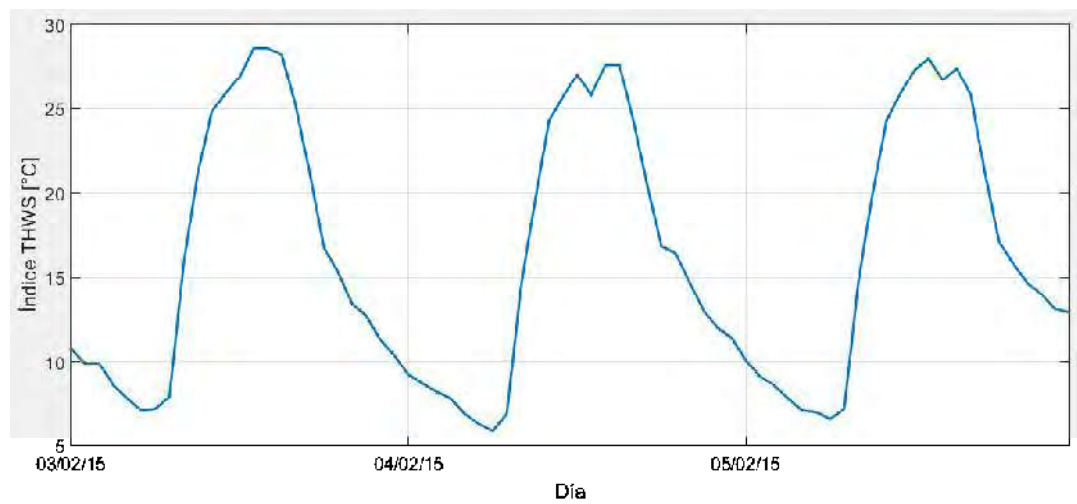


Figura 2.6: Comportamiento del índice THSW durante en los días 3,4 y 5 de Febrero del 2015 en Morelia Michoacán

2.4.6. Velocidad del viento

Como se mencionó anteriormente, la potencia entregada por las celdas fotovoltaicas es sensible a la temperatura de la celda. Dicha temperatura está en función de diferentes parámetros ambientales así como las propiedades de la celda (transmitancia de la cubierta cristalizada, la absorción de la placa, etc.). Así pues, el efecto de la velocidad del viento, influye de manera directa al actuar como refrigerante de la celda, por lo que existe una correlación entre la temperatura de operación de la celda y la velocidad del viento, por lo que la obtención de este parámetro, mejorará la predicción de la temperatura ambiente y subsecuentemente, la temperatura de operación de la celda [S. Mekhilef14]. La Figura 2.7 muestra la velocidad del viento presente en el periodo del día 3 al 5 de Febrero del 2015 en la ciudad de Morelia Michoacán.




Figura 2.7: Comportamiento de la velocidad del viento en la ciudad de Morelia los días 3, 4 y 5 de Febrero del 2015

2.5. Horizontes de predicción

Uno de los mayores retos que enfrenta la generación de energía eléctrica mediante SGFV es el hecho de que no es despachable, es decir, no se puede controlar debido a la variabilidad del recurso solar, así pues se hace necesario el desarrollo de metodologías

de predicción del recurso solar, de manera que sea posible la planeación de la cantidad de potencia que entregarán las unidades generadoras que sí sean controlables y así dar viabilidad a la integración de los SGFV a la red eléctrica. Además, los mercados eléctricos actuales despachan la generación en ventanas de tiempo de un día en adelante, así como en una hora en adelante, por lo que para integrar niveles elevados de generación fotovoltaica en las redes eléctricas actuales, se hace necesario la elaboración de metodologías de predicción para estos horizontes de tiempo [Marquez12].

Adicionalmente, para efectos de planeación, diseño y modificación de redes eléctricas, es necesaria la predicción a largo plazo, sacrificando en parte precisión, pero ofreciendo un panorama del recurso solar que se tendrá a futuro en el lugar donde que se desee instalar un nuevo SGFV.

2.5.1. Predicción a largo plazo (h pasos hacia adelante)

Predicción a largo plazo, usualmente se refiere a la predicción del recurso disponible, en este caso de solar, con un horizonte de meses o hasta un año hacia el futuro. Esta técnica es útil para las compañías suministradoras de energía eléctrica así como para participantes del mercado eléctrico para negociar contratos, planear expansiones de la red, así como para la creación de nuevos SGFV. En general, este método de predicción no ofrece tanta precisión comparados con los de corto y mediano plazo, esto debido a la magnitud de su ventana de predicción, además, es altamente susceptible a la calidad de los datos de mediciones históricas, sin embargo, resulta útil para realizar las proyecciones y los estudios anteriormente mencionados [Letendre14].

2.5.2. Predicción a mediano plazo (1 día en adelante)

La predicción a mediano plazo puede entregar predicciones de hasta un día en adelante. Este tipo de predicciones son de gran utilidad para los operadores de las redes eléctricas, ya que les permitirán tomar decisiones referentes a la operación de la red. En este tipo de pronóstico, las variables meteorológicas se observan desde una perspectiva general, es decir, no se observan mediciones reales tomadas dentro del periodo que se quiere predecir, sino las variables que ocurrieron en un espacio temporal anterior al que se quiere

predecir. Si bien se sigue dependiendo de la calidad de la base de datos, la tendencia que siguen las variables meteorológicas pronosticadas no deberán presentar una variación de gran magnitud, lo que permitirá obtener una predicción, en la mayoría de los casos, más acertada respecto a la obtenida con el método a largo plazo [P. Bacher09].

2.5.3. Predicción a corto plazo (1 hora en adelante)

Las predicciones a corto plazo dependen de una descripción detallada de las condiciones climatológicas que ocurren en un instante antes del punto al que se quiera predecir. Esta técnica de predicción resulta vital para los esfuerzos de integrar la generación fotovoltaica a gran escala a las redes eléctricas actuales, ya que, debido a su corta ventana de predicción, los resultados obtenidos con esta técnica suelen ser muy precisos, sin embargo, es indispensable contar con equipo de medición en tiempo real que ofrezca un elevado grado de confiabilidad en sus mediciones. [M. Paulescu14]

2.6. Predicción de condiciones meteorológicas que influyen en la operación de un SGFV

Debido al rápido incremento de la penetración de SGFV en las redes eléctricas actuales, la predicción de la potencia generada por un SGFV se ha vuelto crítica para las empresas que gestionan estos SGFV así como para los operadores de las redes eléctricas. La importancia de un sistema de predicción aumenta aún más en lugares donde se ha abierto el mercado eléctrico a productores independientes y privados.

A continuación se presentan las metodologías propuestas basadas en RNA's para la predicción de las condiciones meteorológicas antes mencionadas. Para evaluar el funcionamiento de las RNA propuestas, se utilizará la raíz del error medio cuadrado (RMSE).

Para la programación de las RNA's propuestas en esta tesis, se utilizó el *toolbox* de redes neuronales en el software Matlab[®] 2015 a. Los tiempos de cómputo presentados fueron medidos durante la etapa de entrenamiento de las RNA's en un equipo de cómputo con 8 gigabytes de memoria RAM y un procesador AMD[®] Vision A8 el cual cuenta con 4 núcleos físicos.

2.6.1. Predicción de la temperatura

La temperatura de operación de una celda fotovoltaica está ligada a los procesos internos que ocurren en el material semiconductor de la celda, el cual es bombardeado por fotones lo que lleva a la generación de energía eléctrica, pero también a la liberación de energía no convertida a electricidad en forma de calor. Mecanismos estándar de transferencia de calor tales como convección y radiación se deben de tomar en cuenta en el balance de energía del módulo, este procedimiento lleva a la estimación de la temperatura de operación de la celda (T_c).

En esta tesis, la temperatura de operación del módulo se calculará en base a la temperatura ambiente utilizando la siguiente fórmula [S. Mekhilef14]:

$$T_c = T_a + \frac{NOCT - 20}{800} G \quad (2.8)$$

donde T_a es la temperatura del aire en °C, $NOCT$ es la temperatura de operación nominal del módulo utilizado en °C y G es la irradiancia solar en W/m^2 .

T_a será la variable que habremos de predecir, en este trabajo de tesis se utilizarán técnicas de RNA para lograr este objetivo.

2.6.1.1. Predicción a largo plazo

La metodología propuesta, basada en RNA, busca otorgar la libertad de predecir la temperatura ambiente para cualquier día, de cualquier mes. Para la implementación de esta metodología resulta indispensable tener una base de datos de mediciones reales de al menos un año de mediciones ininterrumpidas para el entrenamiento de las RNA. Mientras mayor sea el conjunto de datos de entrenamiento, se obtendrá un mejor resultado en la predicción. Para esta metodología, se utilizaron mediciones meteorológicas reales de los años 2013 y 2014 como entrenamiento, para predecir cualquier día, de cualquier mes del año 2016. La base de datos de entrenamiento, así como los datos de validación fueron obtenidos de una estación meteorológica Vantage Pro 2 instalada en el campus de ciudad universitaria de la UMSNH en Morelia, Michoacán, propiedad del Grupo de Eficiencia Energética y Energías Renovables (GREEN-ER), de la Facultad de Ingeniería Mecánica. La Figura 2.8 muestra el

diagrama esquemático del sistema de predicción de T_a . Se observa que de la base de datos general, se toma la información necesaria para la implementación de las RNA necesarias para la predicción de cada una de las seis variables meteorológicas, estas predicciones ahora, serán las entradas de una nueva RNA, la cual será la encargada de predecir T_a .

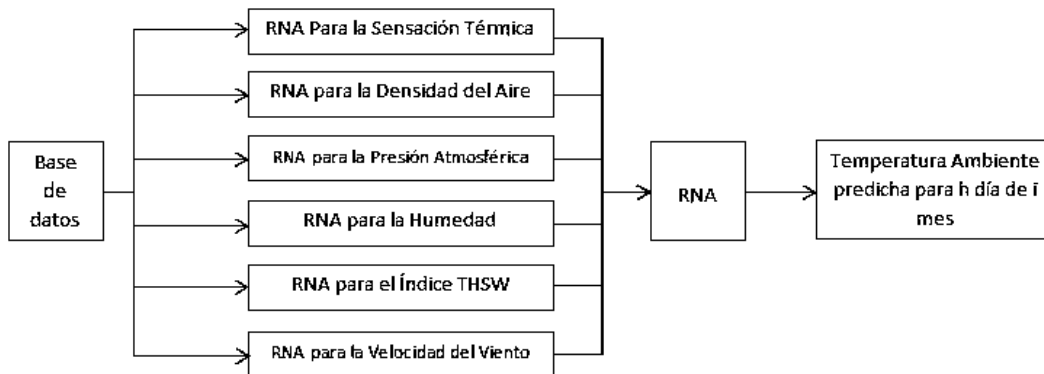


Figura 2.8: Diagrama esquemático del sistema de predicción

Si bien los datos presentes en la base de datos de entrenamiento están en el orden de cientos de miles, un proceso de filtrado de datos se hace necesario antes del entrenamiento de las RNA. Este proceso es necesario para mantener una consistencia lógica en el entrenamiento de las RNA, evitando que ante entradas muy similares, se tengan salidas con una gran diferencia entre ellas, esto debido principalmente, al cambio estacional a lo largo del año. Para lograr esto, se seleccionan únicamente los datos de un día antes, un día después y el día que se desea predecir, si existen los datos en los dos años, se promedian.

2.6.1.1.1. RNA para la sensación térmica Para su implementación, la arquitectura de la RNA propuesta es una red *feedforward* que consta de una sola capa oculta con 200 neuronas y un algoritmo de entrenamiento *backpropagation*. En este caso, la función de entrenamiento es la de gradiente conjugado con reinicios *Powell-Beale* (*traincgb*). La función de transferencia tanto de la capa oculta como la capa de salida es la función simétrica sigmoideal Elliot.

La Tabla 2.1 muestra el vector de mediciones (Y) y el vector de predicciones (\hat{Y}). Se puede observar que para cada predicción existe una medición real, por lo que es posible

el cálculo del *RMSE*. De este punto en adelante, el *RMSE* para evaluar el desempeño de las RNA's usadas para la predicción de las variables meteorológicas requeridas será calculado como se mencionó en la sección 2.3 mediante la fórmula (2.3).

El número de neuronas en la capa oculta se escogió haciendo pruebas y obteniendo la raíz del error medio cuadrático (*RMSE*, por sus siglas en inglés) de la sensación térmica predicha por la RNA propuesta, contra la sensación térmica real medida por la estación meteorológica. Además, se utilizaron tres algoritmos de entrenamiento diferentes: gradiente conjugado con reinicios de *Powell-Beal* (*CGB*), gradiente descendiente con tasa de aprendizaje momentánea y adaptiva (*GDX*) y *Levenberg-Marquardt* (*LM*) para ver cual combinación de algoritmo de entrenamiento y número de neuronas en la capa oculta presentaba el mejor desempeño. En todos los casos se utilizarán los primeros cinco días del mes de marzo del 2015 como casos de estudio. Es importante resaltar, que la selección del número de neuronas en la capa oculta de las RNA's utilizadas para las predicciones se realizó mediante el mecanismo de prueba y error, observando el *RMSE* ya que, debido al alto grado de caos presente en el comportamiento de las variables que se deseaban predecir, la aplicación de técnicas tradicionales no siempre arrojaban el mejor resultado.

La Tabla 2.2 muestra el *RMSE* que se obtuvo con diferente número de neuronas en la capa oculta.

La Figura 2.9 muestra la sensación térmica predicha por la RNA. Como se puede observar, las predicciones de los días 4 y 5 tienen un error más grande que los demás días pronosticados, esto debido a la forma de entrenamiento de la RNA para este horizonte de tiempo, ya que se basa en el promedio del comportamiento de la variable que se desea pronosticar durante los años 2013 y 2014, evidenciando así, que los valores promedio de las diferentes variables utilizadas para la predicción de T_a de esos años fueron menores a los presentados en el año 2015.

2.6.1.1.2. RNA para la densidad del aire La RNA propuesta para el pronóstico de la densidad del aire tiene como entrada la hora del día, y como salida la densidad del aire. La arquitectura de RNA es una red *feedforward* con un algoritmo de entrenamiento *backpropagation* con la función de entrenamiento *Levenberg-Marquardt* (*trainlm*), consta de

Tabla 2.1: Predicciones y mediciones reales de la sensación térmica para el cálculo del RMSE

Hora	Mediciones	Predicciones
01:00	11.5	11.8
02:00	11.1	11.1
03:00	10.4	10.1
04:00	10.1	10.1
05:00	9.6	9.2
06:00	9.3	9.2
07:00	9	8.9
08:00	9.6	9.2
09:00	11.1	10.7
10:00	13.9	13.8
11:00	18.2	17.9
12:00	20.6	20.3
13:00	22.1	21.9
14:00	23.8	23.4
15:00	24.1	24.7
16:00	24.6	24.2
17:00	24.3	23.7
18:00	23.9	23.7
19:00	21.8	21.6
20:00	20.2	19.8
21:00	18.4	17.9
22:00	17.1	17
23:00	15.8	15.8
24:00	14.9	14.8
RMSE=0.3207 °C		

2.6. Predicción de condiciones meteorológicas que influyen en la operación de un SGFV31

Tabla 2.2: RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la sensación térmica

Número de Neuronas	CGB		GDX		LM	
	RMSE	Tiempo (S)	RMSE	Tiempo (S)	RMSE	Tiempo (S)
5	1.5366	20.25	2.1109	21.92	1.5370	84.09
10	1.5344	28.56	1.5450	22.28	1.5325	71.63
50	1.5337	7.69	1.5338	14.46	1.5338	6.78
100	1.5339	8.66	1.5338	20.05	1.5338	6.85
200	1.5331	11.72	1.5339	41.87	1.5338	8.50




Figura 2.9: Sensación térmica predicha por la RNA

una sola capa oculta. La función de transferencia tanto de la capa oculta como la capa de salida es la función logarítmica sigmoïdal. La Tabla 2.3 muestra el desempeño de la RNA observando el RMSE. Se escogieron 3 neuronas ya que se obtiene un buen desempeño, y el esfuerzo computacional es menor. La Figura 2.10 muestra la densidad del aire medida y la obtenida con la RNA.

Tabla 2.3: RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la densidad del aire

Número de Neuronas	CGB		GDX		LM	
	RMSE	Tiempo (S)	RMSE	Tiempo (S)	RMSE	Tiempo (S)
5	0.1082	22.15	0.0839	10.05	0.1082	8.00
10	0.1076	28.60	0.0944	10.09	0.1076	9.04
50	0.1076	7.78	0.1003	10.20	0.1076	6.95
100	0.1076	8.70	0.1063	13.59	0.1076	7.11
200	0.1075	11.43	0.1007	16.69	0.1076	9.67




Figura 2.10: Densidad del aire medida y la obtenida con la RNA

2.6.1.1.3. RNA para la presión atmosférica Para predecir la presión atmosférica se propone una RNA con una capa oculta y 15 neuronas en la misma, la arquitectura de la RNA es del tipo *feedforward* con un algoritmo de entrenamiento *backpropagation* con la función de entrenamiento *traincgb*. Como entrada se tendrá la hora del día y como salida se tendrá la presión atmosférica. La Tabla 2.4 muestra el desempeño de la RNA propuesta variando el número de neuronas en la capa oculta. Se escogieron 50 neuronas debido a que presentaba el mejor desempeño así como el menor tiempo de cómputo.

Tabla 2.4: RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la presión atmosférica

Número de Neuronas	CGB		GDX		LM	
	RMSE	Tiempo (S)	RMSE	Tiempo (S)	RMSE	Tiempo (S)
5	0.9340	21.71	0.9354	21.69	0.9341	53.93
10	0.9343	24.99	0.9394	22.01	0.9342	90.30
50	0.9342	7.72	0.9343	12.55	0.9343	6.72
100	0.9343	8.72	0.9343	18.61	0.9343	6.91
200	0.9343	11.46	0.9343	37.97	0.9343	7.62

La Figura 2.11 muestra la presión atmosférica pronosticada, así como la presión atmosférica medida.

2.6.1.1.4. RNA para la humedad Para la predicción de la humedad, se propone una RNA con una capa oculta y 3 neuronas, la arquitectura de la RNA es *feedforward* con un algoritmo de entrenamiento *backpropagation* con una función de entrenamiento *trainlm*. Como entrada se tendrá la hora del día y como salida se tendrá la humedad. La Tabla 2.5 muestra el desempeño de la RNA propuesta variando el número de neuronas en la capa oculta. En este caso se le dio prioridad al desempeño sobre el esfuerzo computacional, por lo que se escogieron 5 neuronas.

La Figura 2.12 muestra la humedad pronosticada, así como la humedad medida.

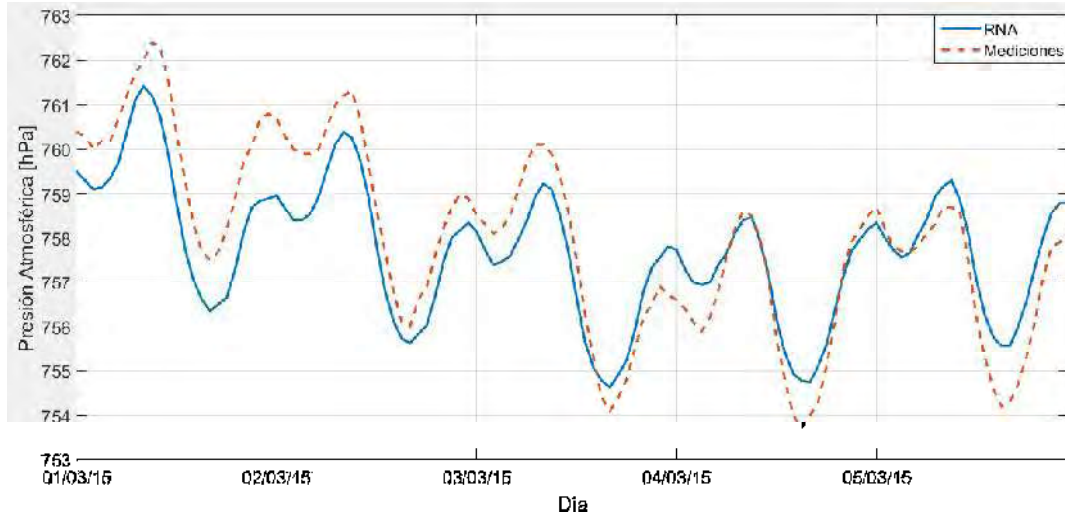


Figura 2.11: Presión atmosférica predicha por la RNA

Tabla 2.5: RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la humedad

Número de Neuronas	CGB		GDX		LM	
	RMSE	Tiempo (S)	RMSE	Tiempo (S)	RMSE	Tiempo (S)
5	4.8121	28.66	4.9256	22.02	4.8084	95.55
10	4.9009	33.04	4.8956	21.88	4.9125	66.52
50	4.9102	7.62	4.9104	15.00	4.9102	6.82
100	4.9110	8.86	4.9104	20.50	4.9104	6.98
200	4.9098	11.54	4.9104	42.29	4.9104	7.71

2.6. Predicción de condiciones meteorológicas que influyen en la operación de un SGFV35




Figura 2.12: Humedad medida y la obtenida con la RNA

2.6.1.1.5. RNA para el índice THSW Para su implementación, la arquitectura de la RNA propuesta es una red feedforward con un algoritmo de entrenamiento backpropagation, en este caso, la función de entrenamiento `traincgb`, consta de una sola capa oculta con 50 neuronas. La función de transferencia de la capa oculta es la función logarítmica sigmusoidal (`logsig`) y la de la capa de salida es la función simétrica sigmusoidal elliot. El número de neuronas en la capa oculta se escogió haciendo pruebas y obteniendo la raíz del error medio cuadrático (RMSE) del índice THSW predicho por la RNA propuesta, contra el índice THSW real medido por la estación meteorológica. La Tabla 2.6 muestra el RMSE que se obtuvo con diferente número de neuronas en la capa oculta. La Figura 2.13 muestra el índice THSW predicho por la RNA.

2.6.1.1.6. RNA para la velocidad del viento La RNA propuesta para el cálculo de la velocidad del viento tiene como entrada la hora del día, y como salida la velocidad del viento. La arquitectura de RNA es una red feedforward con un algoritmo de entrenamiento backpropagation con la función de entrenamiento de gradiente descendiente con una tasa adaptiva de aprendizaje (`traingdx`), consta de una sola capa oculta con 5 neuronas. La función de transferencia tanto de la capa oculta como la capa de salida es la función simétrica

Tabla 2.6: RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA del índice THSW

Número de Neuronas	CGB		GDX		LM	
	RMSE	Tiempo (S)	RMSE	Tiempo (S)	RMSE	Tiempo (S)
5	1.8026	21.31	1.8248	23.43	1.7894	41.99
10	1.7824	33.14	1.7761	23.32	1.7926	72.37
50	1.7929	7.68	1.7939	15.26	1.7939	7.19
100	1.7939	8.80	1.9477	21.74	1.7939	7.44
200	1.7939	12.42	1.7939	45.18	1.7939	8.36

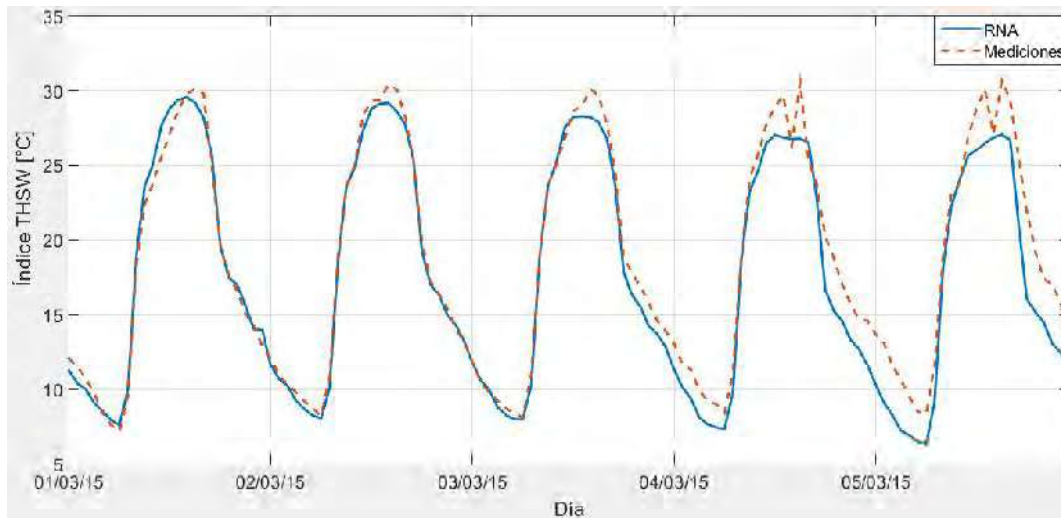


Figura 2.13: índice THSW medido y el obtenido con la RNA

2.6. Predicción de condiciones meteorológicas que influyen en la operación de un SGFV37




Figura 2.14: Velocidad del viento entregada por la RNA con diferente número de neuronas durante el entrenamiento con el algoritmo *traingdx*

sigmusoidal elliot. La Tabla 2.7 muestra el desempeño de la RNA utilizando el RMSE. Se escogieron 5 neuronas ya que se obtiene un buen desempeño, y el esfuerzo computacional es bajo. La Figura 2.15 muestra la velocidad del viento predicha, así como la medida. Observando la curva de las mediciones se puede apreciar que el grado de variación de un instante a otro es muy elevado. Este es un claro ejemplo del nivel de caos presentes en algunos de los datos utilizados. Para evitar problemas de *overfitting* (sobreajuste), se optó por entrenar la RNA de manera que entregara resultados no tan variables, sacrificando el desempeño en el entrenamiento, pero dándole prioridad al desempeño durante la implementación.

A manera de demostración, en la Figura 2.14 se muestran los resultados de entrenar la RNA de la velocidad del viento con diferente número de neuronas. Como se puede observar, si se agregan más neuronas al entrenamiento, durante la implementación la RNA ante cualquier cambio en la entrada tiene un comportamiento más brusco, lo que, en casos en los que las variaciones son tan grandes e impredecibles, resulta perjudicial para el desempeño final de la RNA, por lo que se optó por el entrenamiento que entrega una respuesta más atenuada.

Tabla 2.7: RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la velocidad del viento

Número de Neuronas	CGB		GDX		LM	
	RMSE	Tiempo (S)	RMSE	Tiempo (S)	RMSE	Tiempo (S)
5	1.0047	23.71	1.0023	22.13	1.0033	67.73
10	1.0098	45.16	1.0100	22.36	1.0119	92.10
50	1.0121	7.76	1.0121	12.29	1.0121	6.79
100	1.0121	8.88	1.0121	16.87	1.0121	6.89
200	1.0121	11.07	1.0121	33.76	1.0121	7.61




Figura 2.15: Velocidad del viento predicha contra la medida

2.6.1.1.7. RNA para la temperatura ambiente Una vez que se han predicho todas las variables meteorológicas que se utilizarán para la predicción de la temperatura ambiente se procede implementar la RNA que se encargará de estimar la temperatura ambiente en el día deseado. La red propuesta es una red con una arquitectura MISO (Múltiples entradas, una sola salida). Esta red tendrá como entradas los parámetros ambientales previamente estimados y como única salida tendrá la temperatura ambiente. La Figura 2.16 muestra la arquitectura de la red propuesta. La red planteada es una red feedforward con un algoritmo de entrenamiento backpropagation utilizando la función trainlm. En la capa oculta, se realizaron pruebas con diferente número de neuronas, esto, con el objetivo de encontrar la configuración más adecuada que tuviera un buen desempeño sin emplear mucho esfuerzo computacional. La Tabla 2.8 muestra los resultados obtenidos, se seleccionaron 5 neuronas.

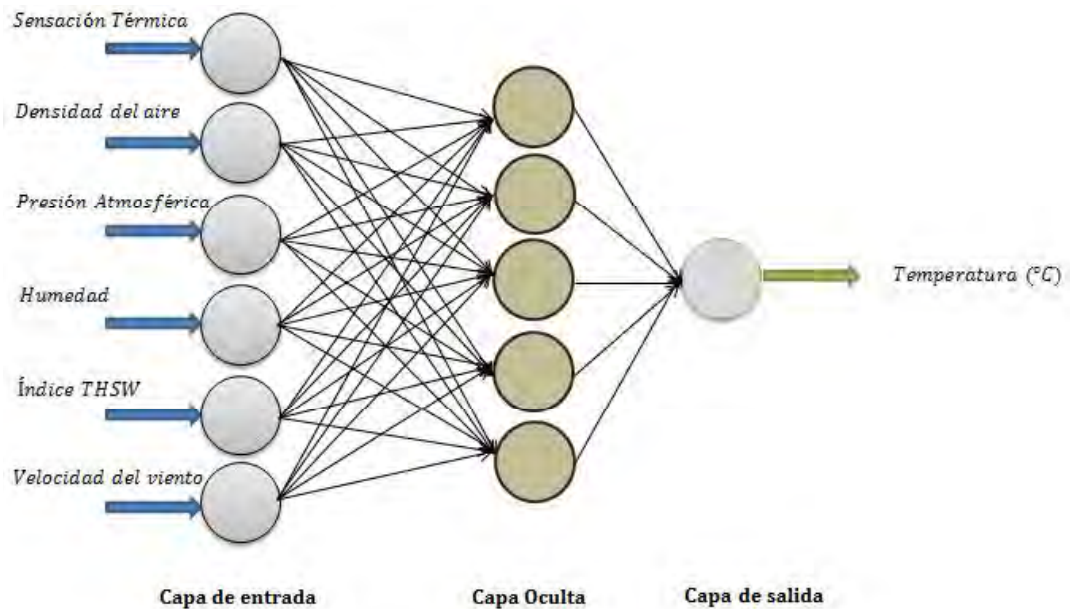


Figura 2.16: Arquitectura de la RNA propuesta para la predicción de T_a

En la Figura 2.17 podemos observar la temperatura ambiente predicha para los casos de estudio propuestos así como la medida por la estación meteorológica. Se puede observar que la predicción es bastante precisa en los primeros tres días, sin embargo, tiene

Tabla 2.8: RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la temperatura

Número de Neuronas	CGB		GDX		LM	
	RMSE	Tiempo (S)	RMSE	Tiempo (S)	RMSE	Tiempo (S)
5	1.4867	17.37	1.5996	13.61	1.4746	4.66
10	1.4801	16.15	1.4813	12.63	1.4844	1.92
15	1.4860	18.64	1.4929	12.81	1.4972	1.82
50	1.6941	16.5	1.7005	13.43	1.6554	2.27
100	3.3045	25.21	1.6554	20.67	1.7422	3.36

un error significativo en los últimos dos. La existencia de este tipo de errores cuando se hace una predicción con un horizonte de tiempo tan amplio es natural, ya que el entrenamiento de las RNA's para esta metodología se basa en el promedio de las condiciones meteorológicas en años pasados, y puede que, ya sea en los años pasados o en el día que se quiere predecir, existiesen condiciones atípicas, causando así, el error que se observa entre la predicción y las mediciones.




Figura 2.17: Temperatura ambiente medida y la obtenida con la RNA

2.6.1.2. Predicción a mediano plazo (Un día hacia adelante)

En caso de que no se tenga acceso a una base de datos lo suficientemente robusta para entrenar las RNA propuestas en la sección anterior, se puede optar por utilizar los datos de $k-1$ y $k-2$, donde k es el día que se desea predecir. En este escenario, se plantea el uso de las mismas RNA propuestas anteriormente, pero en lugar de utilizar como entrenamiento la base de datos de 2013 y 2014, se utilizarán únicamente los datos del 2015, esto con la intención de emular el escenario antes mencionado en el cual no se tenga una base de datos limitada. Además de que, la metodología de un día hacia adelante únicamente trabaja con los dos días anteriores inmediatos, esto, para buscar obtener una buena aproximación de las condiciones meteorológicas del día que se desea predecir.

Una vez estimados los valores de las condiciones meteorológicas relevantes en el día que se desea predecir, se puede proceder a predecir la temperatura ambiente. De igual manera se hace utilizando la RNA propuesta para la temperatura con h pasos hacia adelante, simplemente cambiando la base de datos de entrenamiento. La Figura 2.18 muestra la temperatura predicha contra la real medida con la estación meteorológica.




Figura 2.18: Temperatura predicha contra la medida en la estación meteorológica

La Tabla 2.9 muestra el RMSE en cada una de las variables que se utilizaron para predecir la temperatura, así como el RMSE de las predicciones obtenidas.

Tabla 2.9: RMSE para la predicción de la temperatura utilizando el método de un día hacia adelante

Variable Meteorológica	RMSE
Sensación Térmica	1.3807
Densidad del aire	0.0259
Presión Atmosférica	2.3931
Humedad	5.1866
Velocidad del viento	1.1408
Temperatura	1.2784

2.6.1.3. Predicción a corto plazo (Una hora hacia adelante)

Este tipo de pronóstico, realizado hacia un periodo de tiempo muy corto en el futuro (1 hora) es muy importante para los operadores de la red eléctrica para poder garantizar la operación adecuada de la red. Para realizar este tipo de pronóstico es necesario una estación meteorológica en sitio que éste tomando mediciones automáticamente, de manera que pueda ser implementada de forma inmediata para realizar la predicción del siguiente instante de tiempo.

La metodología propuesta utiliza la misma estructura de RNA para la predicción de h pasos y de un día hacia adelante. La diferencia de este enfoque, radica en el procesamiento de los datos de entrenamiento, pues a diferencia de las dos propuestas anteriores, la única predicción que se realiza utilizando los promedios de los datos históricos es la primera del día (01:00), que definiremos como la predicción n . La Figura 2.19 ilustra el diagrama de flujo del algoritmo propuesto. Una vez realizada la predicción n , las mediciones de las variables meteorológicas reales en el instante n , tomadas por la estación meteorológica son observadas por el algoritmo, el cual, usará toda la base de datos disponible para buscar y encontrar coincidencias. Si no existe una coincidencia exacta, el algoritmo hace uso de una tolerancia positiva y negativa para cada variable meteorológica, esto, con el fin de encontrar una aproximación a los valores de referencia. Una vez que se han encontrado ya sea los valores con una coincidencia exacta, o los más aproximados, el algoritmo identifica la hora en la cual se presentaron estas condiciones meteorológicas, al cual se llamará el instante g .

2.6. Predicción de condiciones meteorológicas que influyen en la operación de un SGFV43

Una vez identificado g , el algoritmo toma los valores de las variables meteorológicas en el instante $g+1$, los cuales se utilizarán como entrenamiento para las RNA, las cuales, una vez entrenadas, pronosticarán los valores de las variables meteorológicas en el instante $n+1$. Una vez hecho esto, las mediciones reales del instante $n+1$ son observadas por el algoritmo y se repite el proceso de búsqueda y filtrado en la base de datos para realizar la predicción en el instante $g+2$. El proceso iterativo termina hasta que se realiza la última predicción (24:00).

En la Figura 2.20 se puede observar la temperatura predicha comparada con la medida. Se observa que el error es mínimo. Lo cual se refleja en la Tabla 2.10 la cual muestra el desempeño de las tres metodologías propuestas. Se observa que si bien la predicción a largo plazo (h pasos hacia adelante) ofrece predicciones cercanas a las mediciones reales, es mejorada por el método de un día hacia adelante, el cual a su vez, es superado por el método de una hora hacia adelante.

Tabla 2.10: Rendimiento de los diferentes métodos para predecir temperatura

Método de predicción	RMSE
Predicción a largo plazo	1.4746
Predicción a mediano plazo	1.2783
Predicción a corto plazo	0.2605

2.6.2. Predicción de la irradiancia

Defínase irradiancia como la potencia por unidad de área producida por el sol en forma de radiación electromagnética, se mide en W/m^2 . La irradiancia puede ser medida tanto en el espacio exterior (irradiancia extraterrestre) como en la superficie terrestre (irradiancia difusa), sin embargo, la incidente sobre la superficie terrestre se verá afectada por los efectos de absorción y dispersión causados por la atmósfera [Boxwell12].

La irradiancia solar es la energía primaria que utilizan los paneles fotovoltaicos para generar energía eléctrica, así como otros dispositivos que utilizan otro tipo de tecnologías, tales como la termosolar. Por esto, la determinación y predicción de la irradiancia solar

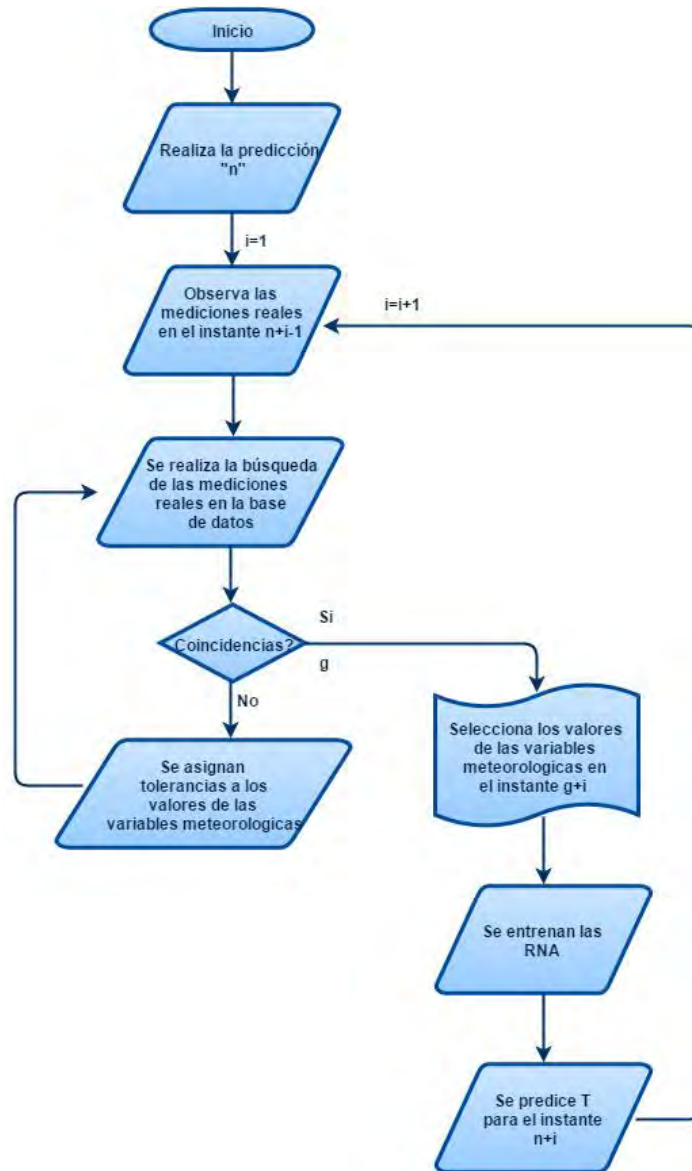


Figura 2.19: Diagrama de flujo para la predicción de T_a con el método de una hora hacia adelante

2.6. Predicción de condiciones meteorológicas que influyen en la operación de un SGFV45




Figura 2.20: Temperatura predicha con el método de una hora hacia adelante contra la temperatura real adelante

es esencial para la operación óptima de estos dispositivos. La irradiancia varía en base a muchos factores, la estación del año, la posición del sol durante el día así como condiciones meteorológicas y la presencia de masas nubosas. A continuación se proponen las técnicas de h pasos hacia adelante, un día hacia adelante y de una hora hacia adelante para la predicción de irradiancia solar [Smil06].

2.6.2.1. Predicción a largo plazo

De la misma forma que se puede predecir la temperatura en h pasos hacia adelante, la irradiancia se puede predecir, siempre y cuando se cuente con la base de datos necesaria para realizar el correcto entrenamiento de la RNA. Al igual que en el caso de la temperatura, se utilizarán variables ambientales previamente estimadas. Las variables ambientales que se utilizarán como entradas en la RNA son la hora del día, la sensación térmica y el índice THSW. La justificación de la selección de estas variables se explica en la Sección 3.1 de este trabajo. La RNA propuesta es una RNA *feedforward* con un algoritmo de entrenamiento *backpropagation* cuya función de entrenamiento es la función *traingdx*. Se plantea una sola capa oculta. El número de neuronas en la capa oculta, así como la función de entrenamiento se escogió haciendo pruebas y observando su rendimiento mediante el RMSE. La Tabla 2.11

Tabla 2.11: RMSE y tiempo de cómputo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA de la irradiancia solar

Número de neuronas	CGB		GDJ		LM	
	RMSE	Tiempo (S)	RMSE	Tiempo (S)	RMSE	Tiempo (S)
5	73.6721	20.54	75.0106	13.00	174.7489	76.25
10	71.4212	20.12	71.8637	13.13	71.5730	17.59
15	71.8776	19.7	71.6177	13.06	73.1443	5.41
50	74.9199	114.4	74.2293	13.46	74.9786	2.13
100	85.9773	12.06	79.7997	21.71	83.3240	2.55

muestra el rendimiento y tiempo de cómputo para diferente número de neuronas en la capa oculta y función de entrenamiento. La Figura 2.21 muestra la irradiancia predicha comparada con las mediciones reales hechas por la estación meteorológica. Como se puede observar en la Figura 2.21, la curva de irradiancia del caso base no presenta grandes picos, lo que significa que no hubo interferencia por parte de masas nubosas entre el sol y la estación meteorológica y por consiguiente los paneles fotovoltaicos. Esta condición variara dependiendo del día del año que se quiera predecir, en el Capítulo 4 se abordará más a detalle en diferentes casos de estudio.

2.6.2.2. Predicción a mediano plazo (Un día hacia adelante)

Para la predicción de un día hacia adelante se planteó el uso de las mismas RNA propuestas para la predicción de la irradiancia utilizando el método de h pasos hacia adelante, el único cambio fue la base de datos utilizada para el entrenamiento. Se propone utilizar los días $k-1$ y $k-2$, donde k es el día que se desea predecir. Los resultados obtenidos se muestran en la Figura 2.22 la cual muestra la irradiancia predicha con la RNA y la real medida por la estación meteorológica. Se puede apreciar que la diferencia entre la real y la pronosticada por la RNA disminuye, esto gracias a que los días utilizados como entrenamiento para la predicción presentaron condiciones meteorológicas similares al día que se deseaba predecir, sin embargo, sigue sin poder pronosticar de manera adecuada en días en




Figura 2.21: Irradiancia medida y la obtenida con la RNA del método de h pasos

los que existe una interferencia nubosa considerable.

2.6.2.3. Predicción a corto plazo (Una hora hacia adelante)

De la misma manera que se puede predecir la temperatura con una hora en adelante, de igual manera se puede hacer con la irradiancia. Este método, si bien tiene una gran limitante, la cual es el intervalo de tiempo hacia el futuro al que se puede predecir, presenta una gran ventaja sobre los dos métodos propuestos anteriormente, pues al realizar las predicciones basándose en incidencias de condiciones meteorológicas similares a las reales en el pasado, puede realizar una predicción implícita de la posición y movimiento de las nubes, por lo que ofrece un resultado mucho más aproximado al real, como se muestra en la Figura 2.23 la cual compara la irradiancia predicha con este método, contra las mediciones reales. Como se puede observar en las Figuras 2.21 y 2.22, los últimos dos días de los datos de validación (4 y 5 de marzo del 2015), presentan interferencia por una masa nubosa, por lo que las predicciones, al utilizar promedios de datos históricos, no son capaces de predecir esta interferencia, lo cual refleja que en los años 2013 y 2014, en los días adyacentes a esas fechas, hubo un cielo completamente despejado. En cambio, en la Figura 2.23 podemos observar que el método de una hora hacia adelante, es capaz de predecir, con mucha precisión

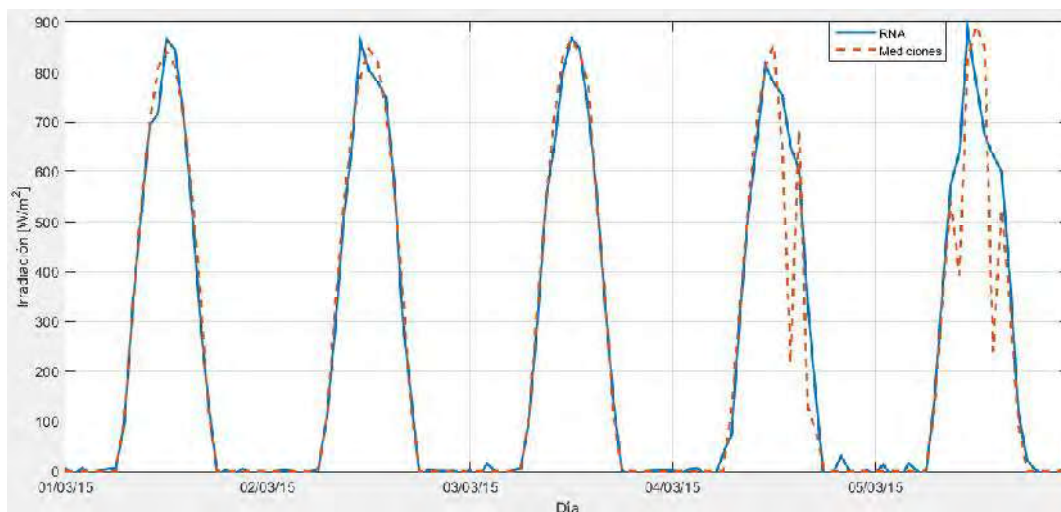


Figura 2.22: Irradiancia medida y la obtenida con la RNA utilizando la técnica de un paso hacia adelante




Figura 2.23: Irradiancia medida y la obtenida con la RNA utilizando la técnica de una hora en adelante

la interferencia nubosa ya que se basa únicamente en condiciones climatológicas.

Además, en la Figura 2.21 se puede observar que durante las horas en las que no debería haber irradiancia (en la noche), la RNA predice valores muy bajos de la misma. Esto se debe a la naturaleza de los datos de entrenamiento, ya que las mediciones reales incluyen los valores de irradiancia de cuando el sol va saliendo o cuando está a punto de ocultarse. Este fenómeno se podría eliminar si únicamente se utilizaran valores de horas sol, es decir, cuando la irradiancia superara cierto umbral (usualmente mayor que $120 W/m^2$) sin embargo, se consideró que era mejor considerar todas las mediciones para el entrenamiento ya que en plantas de gran capacidad, una irradiación por debajo de este umbral aún representa una aportación significativa a la generación total en la red.

La Tabla 2.12 muestra el desempeño utilizando el RMSE de los tres métodos. Observando los resultados, se valida la mayor eficacia del método de una hora hacia adelante, respecto a los otros dos métodos propuestos.

Tabla 2.12: Desempeño de los diferentes métodos para predecir la irradiancia solar

Método de predicción	RMSE
Predicción a largo plazo	78.9537
Predicción a mediano plazo	71.4212
Predicción a corto plazo	32.8785

2.6.3. Conversión de la temperatura ambiente a la temperatura de operación del módulo

Para poder utilizar la temperatura como parámetro para estimar la potencia de salida de un panel fotovoltaico, es necesario convertir la temperatura ambiente a la temperatura de operación de la celda fotovoltaica. Típicamente, la temperatura de un módulo fotovoltaico está definida a $25\text{ }^\circ\text{C}$ cuando incide $1000 W/m^2$. Sin embargo, cuando opera en campo, normalmente operan a temperaturas más altas y generalmente a irradiaciones más bajas. Para determinar la potencia de salida del módulo, es importante determinar la

temperatura de operación del módulo. La temperatura nominal de operación de la celda (*NOCT*, por sus sigla en inglés) está definida como la temperatura alcanzada por celdas en circuito abierto bajo las siguientes condiciones: Una irradiancia de 800 W/m^2 en la superficie de la celda. Una temperatura ambiente de 20°C y una velocidad del viento de 1 m/s . La temperatura de operación del módulo será calculada con (2.8). La *NOCT* está definida para cada panel específicamente, por lo que el ajuste de la temperatura ambiente a la temperatura de operación del módulo dependerá del módulo que se esté utilizando. En el Capítulo 4 de esta tesis se ahondará más en el tema.

Como ya se mencionó anteriormente, el desempeño de las diferentes metodologías de predicción, tanto para la temperatura como para la irradiancia variará dependiendo de si son días soleados, parcialmente nublados o nublados, sin embargo, observando el RMSE se puede concluir que las tres metodologías ofrecen resultados adecuados. En [S. Pelland11] se utilizan datos del Centro Meteorológico Canadiense para realizar la predicción de la irradiancia. Se menciona que en días nublados, su metodología puede llegar a tener un *RMSE* normalizado de hasta un 15 %. Si se normalizan los resultados obtenidos con las tres metodologías propuestas conforme a la fórmula (2.8) y se expresa en forma porcentual se tiene que el *NRMSE* (RMSE normalizado) para la metodología a largo plazo es del 8.77 %, a mediano plazo del 7.93 % y a corto plazo del 3.65 %. Lo que valida el buen funcionamiento de las metodologías propuestas.

$$NRMSE = \frac{RMSE}{Y_{iMAX} - Y_{iMIN}} \quad (2.9)$$

2.7. Conclusiones del Capítulo

En este capítulo se presentaron tres metodologías para el pronóstico de G y T_a . Cada metodología corresponde a un horizonte de tiempo diferente. Uno de los mayores retos fue la selección del número de neuronas en la capa oculta, ya que, como se mencionó anteriormente, al aplicar los criterios mencionados en diferentes referencias [K. Hansen90] y [H. Steinherz01] no se tuvieron, así que se optó por usar el criterio de prueba y error, obteniéndose así mejores resultados.

Otra consideración que se tuvo fue al momento de evaluar el desempeño de las

RNA's, ya que tradicionalmente, esto se hace comparando los resultados obtenidos con la RNA cuando se le dan como entrada los datos utilizados en el entrenamiento con las salidas deseadas utilizadas en el entrenamiento [Yun98]. Sin embargo, al utilizar esta forma de evaluar el desempeño, se podía incurrir en el fenómeno de sobreajuste, el cual ocurre generalmente cuando la estructura de una RNA es ajustada para un caso muy específico, pero cuando se desea aplicar con datos diferentes a los presentados en el entrenamiento, la función de desempeño (en este caso evaluada con el RMSE) aumenta de manera impredecible. Por lo anterior se optó por priorizar el desempeño en la aplicación por sobre el desempeño en el entrenamiento.

Capítulo 3

Caracterización de Unidades de Generación Fotovoltaicas

Debido a los nuevos retos ambientales presentes alrededor del mundo, se hace necesaria una forma de generación de energía limpia, sustentable y confiable. La generación eléctrica mediante paneles fotovoltaicos puede ofrecer una solución ante estos retos, por eso resulta de vital importancia, la caracterización y modelado precisos de las celdas fotovoltaicas e inversores. La integración de la potencia generada por sistemas fotovoltaicos a la red presenta un gran reto a los operadores del sistema, esto debido a su naturaleza intermitente e incontrolable, de ahí la importancia de la predicción de potencia en sistemas fotovoltaicos, pues es una vital herramienta para los operadores de la red al momento de planear y ejecutar el despacho de las unidades generadoras dentro del sistema de potencia.

En este capítulo, se presenta la caracterización de los paneles fotovoltaicos utilizando RNA's. Además se realizó la caracterización de el inversor de un SGFV instalado en la División de Estudios de Posgrado de la Facultad de Ingeniería Eléctrica de la UMSNH, el cual consta de tres arreglos de 12 paneles fotovoltaicos SOLARTEC S72PC-300 conectados en serie, cada panel tiene una capacidad de 300 W bajo condiciones de prueba estándar (STC) [FSEC10]. La Figura 3.1 muestra los parámetros eléctricos del panel, entregados por el fabricante en la hoja de datos.

Como se puede observar, el fabricante del panel solo entrega los parámetros del

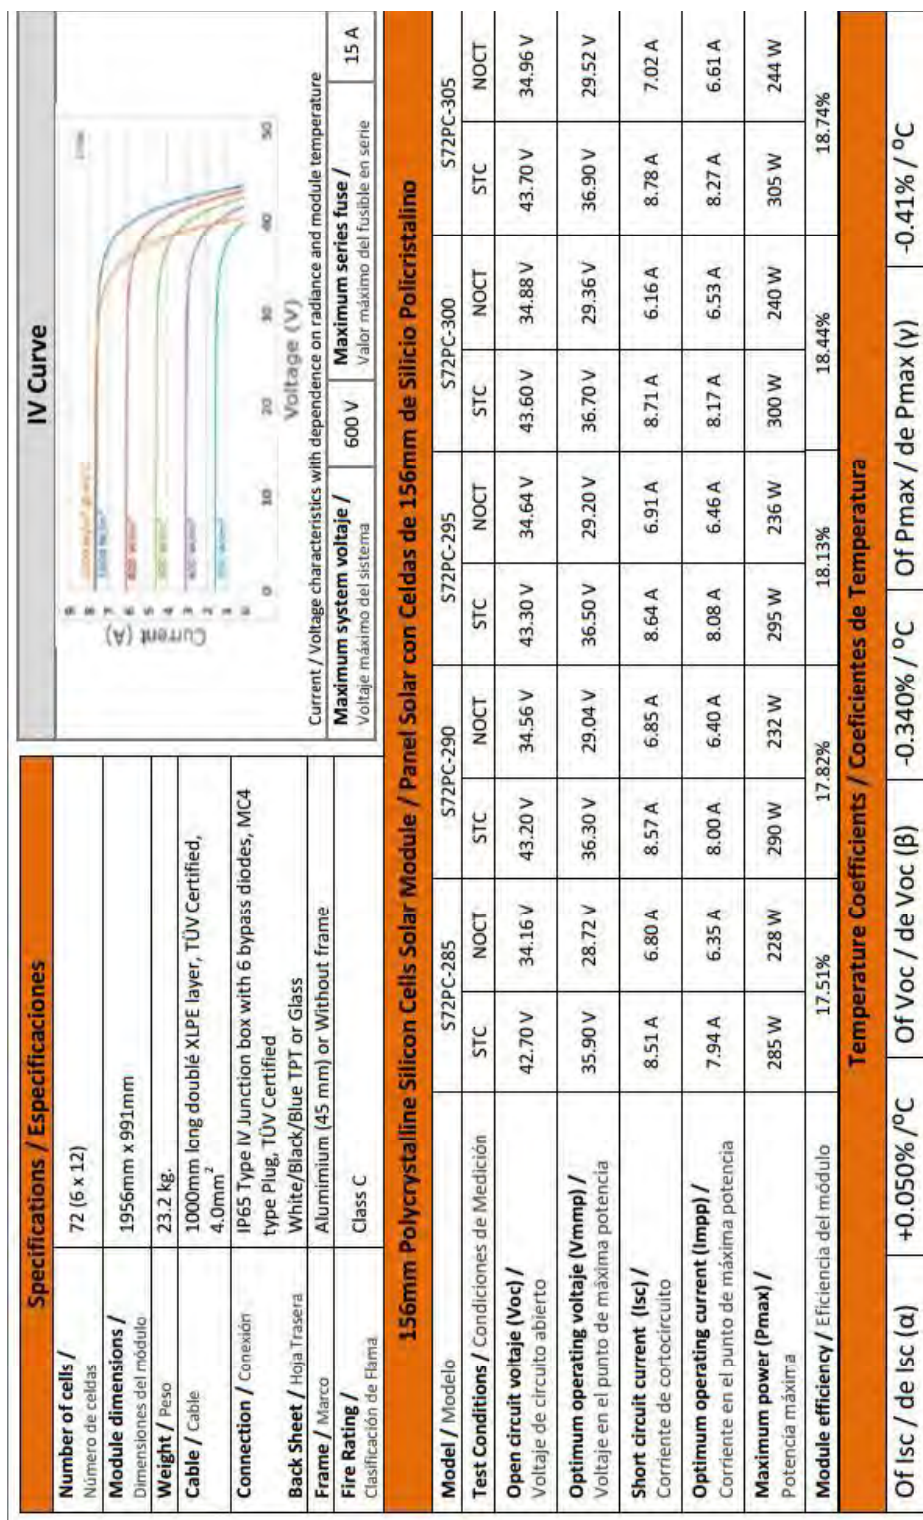


Figura 3.1: Hoja de datos del panel S72PC-300

panel bajo STC y NOCT, es decir, únicamente es dos puntos de operación. En la realidad, estos parámetros no representan los puntos de operación que usualmente se encontrarían en la operación diaria del panel, sin embargo, a partir de estos parámetros se pueden generar modelos matemáticos que representen el comportamiento del panel bajo puntos de operación distintos [D. Sera07]. En [J. Sánchez15], se realizó una comparación entre modelos matemáticos clásicos contra la caracterización realizada con RNA's, de dos paneles de diferente fabricante y capacidad, y se compararon con la potencia de salida de los paneles. Los resultados obtenidos demuestran que la caracterización con RNA's es la más cercana a la potencia de salida. En esta tesis, se modificó la forma de entrenar la RNA, pues se utilizaron mediciones reales, esto, buscando mejorar su rendimiento, ya que, las mediciones, entrada-salida, consideran las pérdidas por polvo o suciedad en la superficie del panel, así como las pérdidas ohmicas causadas por el cableado interno del panel cosa que los modelos matemáticos no hacen. Las RNA son capaces de aprender a través de la experiencia o entrenamiento, es decir, son métodos auto adaptivos guiados por datos. Aprenden de ejemplos y captan las relaciones existentes entre los datos, aun cuando estas relaciones sean desconocidas o difíciles de explicar matemáticamente. La caracterización mediante redes neuronales es muy útil en los casos en los que es más fácil obtener datos del fenómeno o sistema, que generar un modelo matemático preciso [Karatepe03].

3.1. Descripción del SGFV a caracterizar

Si bien se busca que la aplicación de la metodología de caracterización sea generalizada, es necesario caracterizar un SGFV en específico para realizar la validación de la metodología. En este trabajo, se caracterizó el SGFV instalado en la División de Estudios de Posgrado de la Facultad de Ingeniería Eléctrica de la UMSNH. El SGFV, tiene una capacidad instalada de 10.8 kWp (Kilo-Watts pico), esto bajo STC, consta de 3 arreglos de paneles fotovoltaicos, cada arreglo con una capacidad de 3.6 kWp . Además, cada arreglo cuenta con un inversor SMA Sunny Boy SB5000US con una capacidad de hasta 5 kW , el cual opera a un factor de potencia unitario, es decir, entrega solamente potencia activa. El inversor realiza la interconexión con la red de distribución a una tensión de 440 V. Las

mediciones de las variables eléctricas del SGFV se obtuvieron mediante la interfaz *Webbox*, la cual consta de tarjetas de adquisición de datos (DAC, por sus siglas en inglés) instaladas en los inversores y conectadas vía ethernet a un concentrador (mostrado en la Figura 3.2) que a su vez es conectado por un puerto serie a un servidor. El servidor ofrece al usuario un sitio web el cual permite la explotación y obtención de las variables sensadas mediante las DAC's. Mediante esta interfaz, se pueden obtener entre otras, mediciones de potencia de CD, potencia de CA, toneladas de CO_2 no producidas mediante generación tradicional, balances energéticos entre la red eléctrica y el SGFV etc.



Figura 3.2: Interfaz Webbox

En la Figura 3.3 se presenta un diagrama del SGFV en la DEP-FIE. Como se puede observar, la energía generada es consumida por la carga más cercana (el edificio de la DEP-FIE), en caso de que exista un excedente, este irá a la red de CFE, caso contrario, si existe una deficiencia de generación con respecto a la carga del edificio, la red eléctrica de CFE entregará la energía necesaria.

Este SGFV, está instalado en la ciudad de Morelia. La Figura 3.4 muestra el mapa de irradiación solar diaria en kWh/m^2 . Como se puede observar, el estado de Michoacán entra en un rango medio, con una irradiación diaria que oscila entre los 5.5 y 6.0 kWh/m^2 .

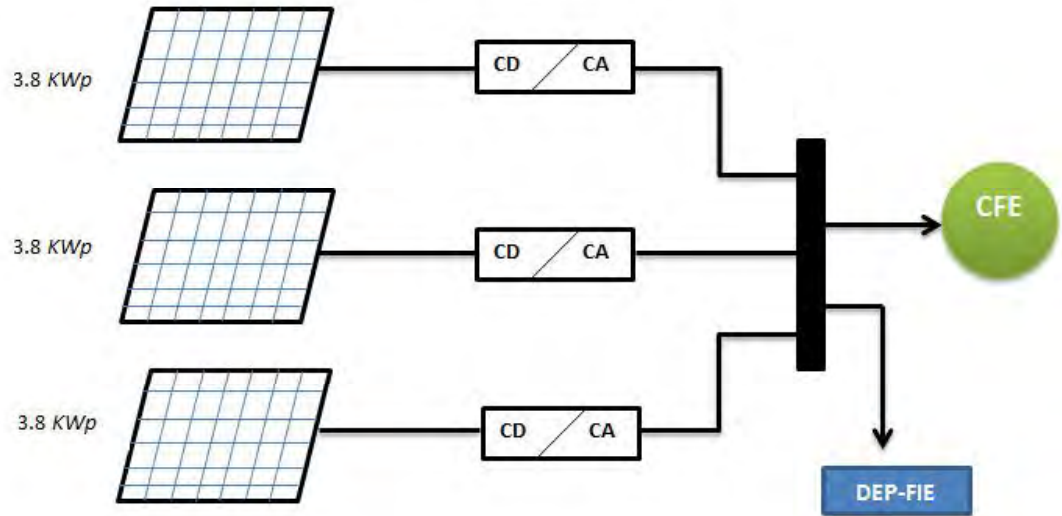


Figura 3.3: Diagrama esquemático del SGFV

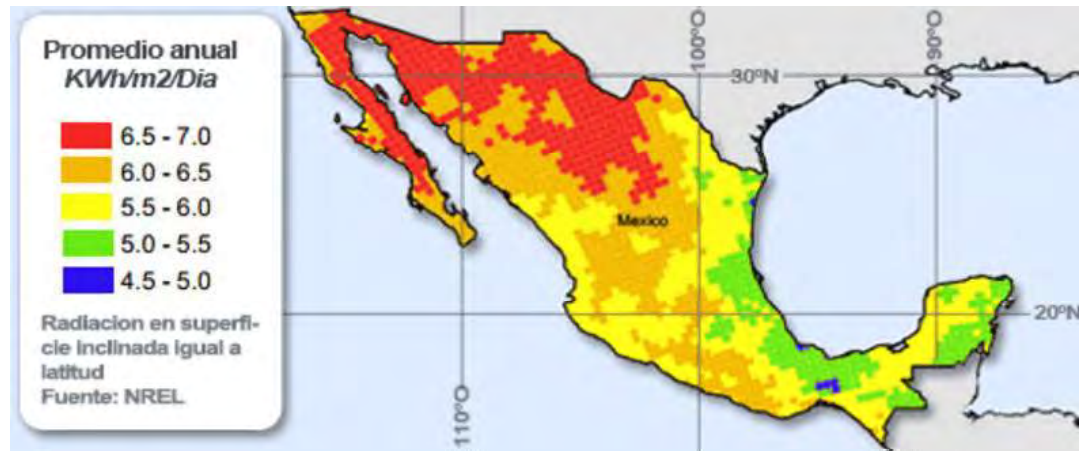


Figura 3.4: Mapa de irradiación solar diaria en México

3.2. Descripción de la RNA propuesta

Debido a la naturaleza variable de la fuente primaria de energía en los sistemas fotovoltaicos (irradiación solar), la caracterización de los componentes del sistema de generación presenta un reto significativo, aunado a esto, el usuario solo tendrá acceso a datos de operación básicos y bajo condiciones de prueba estándar (STC). Métodos clásicos para el modelado y caracterización de paneles fotovoltaicos han sido propuestos anteriormente [Osterwald86], [G. Araujo82b], [S. Samkeliso15b]. El método propuesto en esta tesis, basado en redes neuronales, busca alcanzar una aplicación generalizada, pues al necesitar únicamente mediciones históricas para su entrenamiento, puede ser aplicado para paneles de distinta capacidad, diferente tecnología de fabricación y bajo cualquier condición de operación, arrojando además, resultados precisos y confiables.

Debido a que el objetivo de este trabajo es poder conocer la salida de potencia de cualquier arreglo de paneles, resulta necesario realizar el entrenamiento de nuestras redes neuronales con mediciones tomadas del arreglo a caracterizar, o idealmente, si la hoja de datos de los paneles usados incluye las curvas voltaje-corriente para diferentes temperaturas e irradiaciones.

Se crea entonces una RNA feedforward con estructura MISO (multiple inputs, single output), con una capa oculta, la cual tendrá dos entradas (G y T_c) y como única salida tendrá la potencia generada (P). La Figura 3.5 muestra la arquitectura de la red propuesta.

3.2.1. Entrenamiento de la RNA propuesta

Al realizar el entrenamiento de la RNA, se hicieron ciertas consideraciones, las cuales se explican brevemente a continuación. La selección del número de neuronas en la capa oculta así como la función de entrenamiento se realizó con un procedimiento de prueba y error, el cual consistió en observar el MSE de la RNA propuesta variando el número de neuronas así como la función de entrenamiento contra las mediciones de potencia reales. Los resultados se muestran en la Tabla 3.1, en la cual se puede observar que la configuración óptima es la que utiliza seis neuronas en la capa oculta y es entrenada con la función

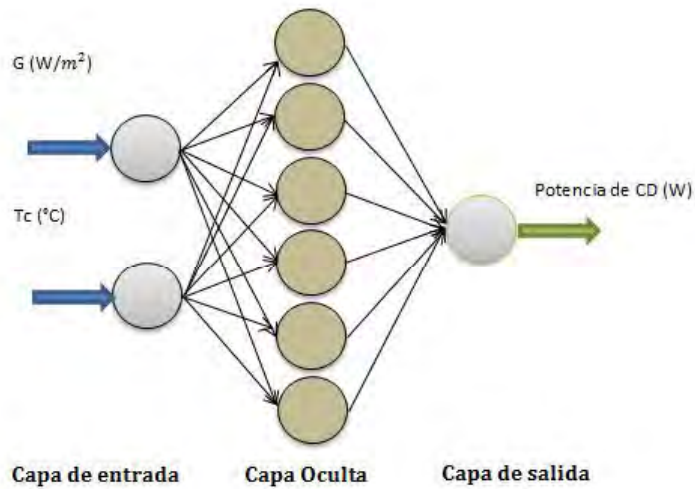


Figura 3.5: Estructura de la RNA usada para la caracterización del arreglo fotovoltaico

trainlm. Los datos de entrada que se utilizaron, tanto para el entrenamiento como para la validación, fueron obtenidos de la estación meteorológica instalada en el campus la UMSNH en Morelia Michoacán. Los datos de la potencia generada utilizados para el entrenamiento y la validación fueron obtenidos directamente del inversor del arreglo fotovoltaico.

Se seleccionaron las mediciones de tres días (3, 4 y 5) del mes de Febrero del presente año para realizar el entrenamiento. Se buscó que estos días tuvieran la menor cantidad de interferencia nubosa, de manera que existiera la mayor cantidad de datos de irradiación y temperatura posibles.

Se entiende que entre más días de entrenamiento tenga la RNA, mejor será el desempeño, desafortunadamente, al momento de la realización de este trabajo no se contaban con más de 15 días totales de mediciones utilizables, por lo que se decidió utilizar solamente tres días para el entrenamiento para utilizar el resto de días con mediciones utilizables como casos de estudio. Los días seleccionados para el entrenamiento (mostrados en la Figura 3.6) fueron seleccionados buscando que la interferencia nubosa fuera mínima y así lograr que la RNA fuera entrenada con valores de irradiancia que van desde cero hasta un un valor máximo, logrando así, eficientar la poca disponibilidad de datos y a la vez dando un entrenamiento que posibilite a la red su correcta implementación para valores de G que

Tabla 3.1: RMSE y tiempo de computo para diferentes funciones de entrenamiento y número de neuronas en la capa oculta de la RNA que caracteriza el arreglo fotovoltaico

Número de Neuronas	CGB		GDX		LM	
	RMSE	Tiempo (S)	RMSE	Tiempo (S)	RMSE	Tiempo (S)
2	59.8800	2.82	59.2833	5.47	61.2420	6.22
4	57.9977	2.18	68.4564	4.96	54.3172	11.10
6	59.8139	3.97	75.9530	5.08	56.4771	38.70
8	59.6352	4.95	71.3094	5.12	56.3491	35.68
10	78.9509	9.16	84.5138	5.11	59.9576	35.00

se encuentren dentro de ese intervalo. La representación gráfica de las mediciones utilizadas para el entrenamiento se muestra en la Figura 3.6.

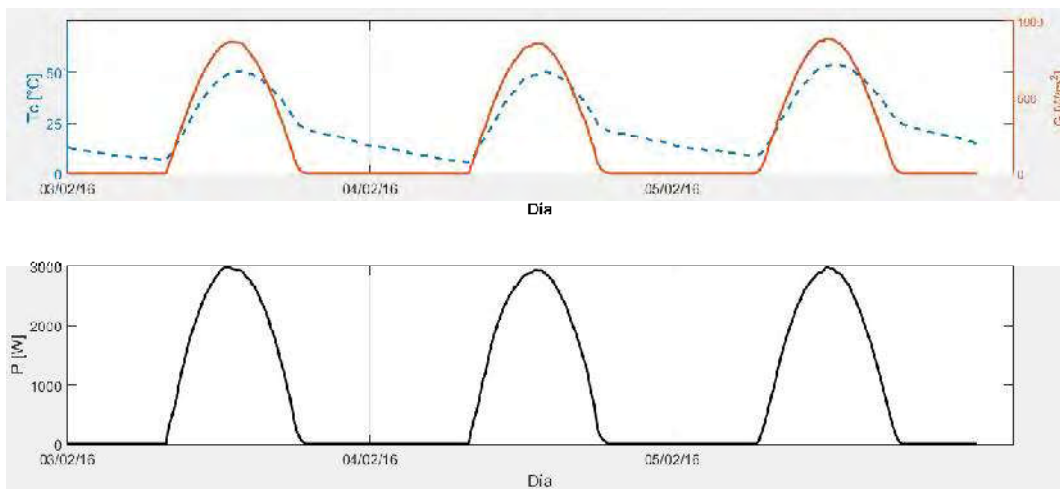


Figura 3.6: Gráfica de los datos utilizados para el entrenamiento

La Figura 3.7 muestra el histograma de errores del entrenamiento de la RNA propuesta, la magnitud del error esta dada en Watts. Se observa que la mayoría de los errores ocurren en el valor mas cercano al error cero, por lo que se toma como adecuado el entrenamiento de la RNA.

Al igual que con las RNA's que se propusieron para la predicción de las condiciones

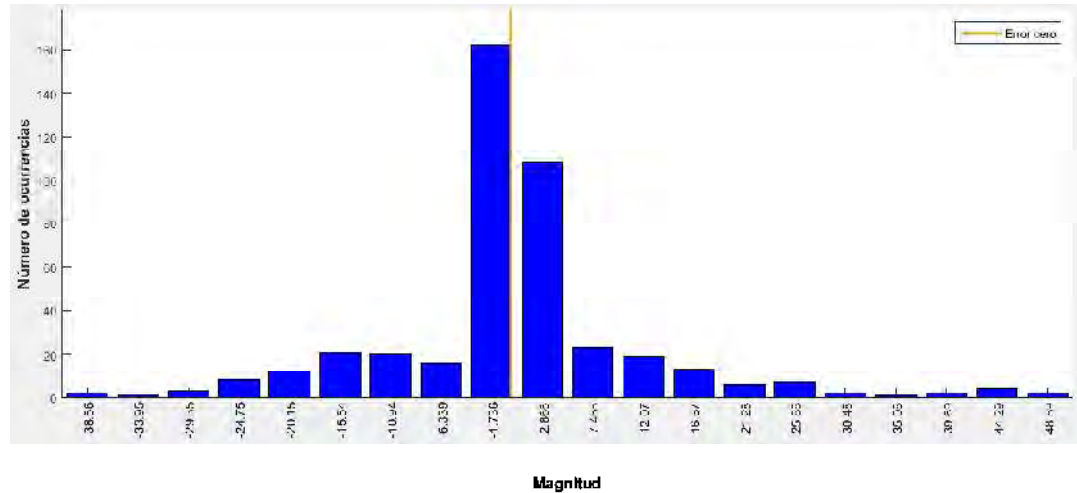


Figura 3.7: Histograma de error de la RNA propuesta

meteorológicas, el desempeño de la RNA para la caracterización del arreglo fotovoltaico se definió observando el $RMSE$. La Figura 3.8 muestra la comparación de la potencia de CD (P_{CD}) respecto a G ; en la parte izquierda se observan los valores de P_{CD} y G que se utilizaron durante el entrenamiento (línea roja) y los valores de G obtenidos con la RNA utilizando como entrada los valores con los que fue entrenada (línea sólida). El $RMSE$ del entrenamiento para esta arquitectura de la RNA fue de 20.5152 y el obtenido durante la implementación fue de 56.6265.

En la Figura 3.9 se presenta la misma comparación, pero esta vez, se le dio prioridad al desempeño durante el entrenamiento y no al de la implementación; el $RMSE$ del entrenamiento para esta arquitectura de la RNA fue de 4.4643 y el obtenido durante la aplicación fue de 1746.1. Se puede observar claramente que si bien el desempeño resulta bastante bueno, no es así en la implementación, ya que causa un sobreajuste elevado, causando que el $RMSE$ crezca de manera significativa.

3.3. Validación de la RNA propuesta

Una vez implementada la RNA propuesta, se escogieron tres días del mes de Febrero para realizar la validación de la caracterización del arreglo fotovoltaico. Los días




Figura 3.8: Gráfica P_{cd} vs G del entrenamiento de la RNA con la arquitectura propuesta y la implementación de la misma




Figura 3.9: Gráfica P_{cd} vs G del entrenamiento de la RNA con una arquitectura que de prioridad al desempeño durante el entrenamiento

seleccionados fueron los días 9, 10 y 11 de Febrero.

Se escogieron estos días, tratando de que se presentaran distintos niveles de irradiación, para demostrar como la RNA es capaz de reaccionar ante cambios repentinos en la irradiación incidente, es decir, cuando se presenta interferencia nubosa entre el sol y el arreglo fotovoltaico. La Figura 3.10 muestra la potencia real para el día 9 (línea punteada) contra la potencia entregada por la RNA (línea sólida). Se puede observar que se presentó una concentración nubosa pasajera, en lo que se podría definir como un día parcialmente nuboso, pues, si bien hubo interferencias, en algunos momentos del día hubo la suficiente irradiación para que el arreglo alcanzara valores de potencia cercanos a la nominal.




Figura 3.10: Potencia real del 9 de Febrero contra la obtenida con la RNA

La Figura 3.11 muestra la potencia real para el día 10 (línea punteada) contra la potencia entregada por la RNA (línea sólida). Como se ve claramente, no existen tantos cambios repentinos en la magnitud de la potencia entregada por el arreglo, lo que representa que la interferencia nubosa fue mínima, así que se podría decir que fue un día soleado, obteniéndose mayor cantidad de potencia con referencia al día 9.

La Figura 3.12 muestra la potencia real para el día 11 (línea punteada) contra la potencia entregada por la RNA (línea sólida). A diferencia de los otros dos días, el día 11 hubo una presencia permanente de nubes, en lo que se podría definir un día nublado. Como




Figura 3.11: Potencia real del 10 de Febrero contra la obtenida con la RNA

es de esperarse, la potencia de salida del arreglo se ve significativamente reducida.

3.4. Comparación de la caracterización con RNA's contra modelos clásicos

Como se mencionó anteriormente, a través del tiempo se han propuesto diversos modelos matemáticos para paneles fotovoltaicos. Sin embargo, estos modelos, al no considerar los distintos tipos de pérdidas implícitas en el funcionar diario de un módulo fotovoltaico, no pueden ofrecer resultados cien por ciento acertados [A. Ndiaye13].

3.4.1. Modelo de Osterwald

Uno de los modelos más simples, es el propuesto en [Osterwald86]. Al ser un modelo lineal, aun es usado frecuentemente. La ecuación (3.1) es propuesta por este modelo para obtener la potencia máxima bajo un punto de operación establecido.

$$P_m = P_{m_{STC}} \frac{G}{G_{STC}} [1 - \gamma(T_c - T_{STC})] \quad (3.1)$$

Dónde P_m es la potencia máxima del panel, $P_{m_{STC}}$ es la potencia máxima de salida del panel en STC , γ es el coeficiente de temperatura del panel, G_{STC} es la irradiancia definida




Figura 3.12: Potencia real del 11 de Febrero contra la obtenida con la RNA

en STC , G es la irradiancia real, T_{STC} es la temperatura definida en STC y T_c es la temperatura de operación del panel.

3.4.2. Modelo de Araujo-Green

El enfoque presentado por Araujo-Green busca mantener un grado de simpleza al seguir siendo un modelo lineal, pero a la vez, busca ofrecer resultados más precisos respecto a otros modelos lineales, por lo que el modelo se define en una serie de ecuaciones (3.2)-(3.7). Este modelo es explicado a detalle en [G. Araujo82a]

$$I_{SC} = G \frac{I_{SC_{STC}}}{G_{STC}} \quad (3.2)$$

Dónde $I_{SC_{STC}}$ es la corriente de corto circuito en STC e I_{SC} es la corriente de corto circuito en función de la irradiancia real.

$$V_{oc} = V_{oc_{STC}} - 0.0023(T_c - 25) \quad (3.3)$$

Dónde $V_{oc_{STC}}$ es el voltaje de circuito abierto en STC y V_{oc} es el voltaje de corto circuito en un punto de operación en función de la temperatura de operación del panel.

$$a = V_{oc} + 1 - 2V_{oc}r_s \quad (3.4)$$

Dónde r_s es una resistencia estándar del panel.

$$b = \frac{a}{1+a} \quad (3.5)$$

$$V_m = V_{oc} \left[1 - \frac{b}{v_{oc}} \ln(a) - r_s(1 - a^{-b}) \right] \quad (3.6)$$

Dónde V_m es el voltaje en el punto de máxima potencia y v_{oc} es el voltaje estándar de la celda.

$$I_m = I_{SC}(1 - a^{-b}) \quad (3.7)$$

Dónde I_m es la corriente en el punto de máxima potencia.

Una vez que se conocen los valores de I_m y V_m se puede obtener la potencia máxima en un punto de operación específico.

3.4.3. Modelo de un diodo

Basándose en los datos proporcionados por el fabricante en la hoja de datos del panel, es posible obtener un modelo del panel, usando el circuito equivalente de un diodo. Este modelo se explica a detalle en [S. Samkeliso15a]. La ecuación (3.9) define la corriente del panel.

$$v_t = \frac{A.K.T_{STC}}{q} \quad (3.8)$$

Dónde v_t es el voltaje térmico, A es el factor de idealidad del diodo, K es la constante de Boltzmann y q es la carga del electrón.

$$i = I_{ph} - I_o \left(\frac{e^{v+iR_s}}{n_s v_t} - 1 \right) - \frac{v + iR_s}{R_{sh}} \quad (3.9)$$

Dónde I_{ph} es la corriente fotogenerada en STC , I_o es la corriente de saturación de sombra en STC , n_s es el número de celdas conectadas en serie dentro del panel, R_s es la resistencia serie del panel y R_{sh} es la resistencia paralelo del panel.

3.4.4. Comparación de los modelos

En [J. Sánchez15] se realizó la caracterización utilizando RNA's de los paneles Solarex MSX-60 y Kyocera K200GT con una capacidad de generación de 60 Wp y de 200 Wp

respectivamente. Además, se modelaron estos paneles utilizando dos modelos algebraicos [Osterwald86] y [G. Araujo82a] y un modelo que considera la no linealidad del comportamiento de los panel fotovoltaicos [S. Samkeliso15a]. Para la caracterización mediante RNA's, se obtuvieron pseudomediciones utilizando el modelo reportado en [Shiwanda13] para ambos paneles. Los datos de entrenamiento de la RNA se muestran en la Tabla 3.2.

Como se puede ver de la Tabla 3.2, las pseudomediciones representan puntos de operación muy específicos, lo que ayudara a que la caracterización este adecuada para ofrecer buenos resultados ante cualquier condición meteorológica a la que operen los paneles. las Figuras 3.13 y 3.14 muestran una comparación gráfica de la potencia de CD obtenida operando con las condiciones meteorológicas reales del día 15 de Julio del 2015 para cada uno de los paneles utilizando los modelos clásicos y la caracterización mediante RNA, y comparándolos a su vez, con el modelo utilizado como base [Shiwanda13]




Figura 3.13: Potencia de salida para el panel KC200GT usando los modelos clásicos y las RNA's

En la Tabla 3.3 se puede observar una comparativa del MSE y el MAE obtenidos para cada uno de los paneles, utilizando cada una de las metodologías de modelado. Como se puede apreciar, el MAE obtenido mediante la caracterización con RNA's es el más pequeño, y el obtenido con el método de Osterwald es el más grande, esto, sucede en los dos paneles, por lo que se puede decir que la metodología de caracterización con RNA's para paneles

Tabla 3.2: Pseudomediciones para la caracterización de los paneles MSX-60 y KC200GT mediante RNA's

G [W/m^2]	T [$^{\circ}\text{C}$]	P [Watts]	
		MSX-60	KC200GT
1000	0	60.2301	201.5975
1000	25	59.3936	195.8127
1000	50	58.4515	193.4119
1000	75	57.1667	189.8516
800	0	48.0812	162.5236
800	25	47.1202	157.8853
800	50	45.9127	154.1793
800	75	44.9408	151.1061
600	0	35.4118	120.9644
600	25	34.6155	118.1696
600	50	33.8761	115.5084
600	75	32.9277	112.2574
400	0	22.9122	79.7497
400	25	22.34445	77.655
400	50	27.7597	75.1682
400	75	21.1482	73.0365
200	0	10.6459	38.2547
200	25	10.3497	37.0366
200	50	10.0262	35.7602
200	75	9.6875	34.4692
0	0	0	0
0	25	0	0
0	50	0	0
0	75	0	0




Figura 3.14: Potencia de salida para el panel MSX-60 usando los modelos clásicos y las RNA's

fotovoltaicos es la más adecuada.

Tabla 3.3: MSE y MAE para los diferentes métodos de modelado empleados en ambos paneles

	Osterwald		RNA		Araujo-Green		1 Diodo	
Panel	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
KC200GT	142.2756	7.1383	0.2922	0.3348	8.4401	2.0262	45.1646	3.7072
MSX-60	14.7854	2.4398	0.0786	0.1782	1.3886	0.8438	1.9194	0.7582

3.5. Caracterización del inversor

La potencia de salida mostrada en la sección anterior corresponde a la potencia de corriente directa (CD) producida por los paneles, sin embargo, es necesario convertir esta potencia a una potencia de corriente alterna (CA) para que sea posible utilizarla en las cargas más cercanas al SGFV y si existiera un excedente, enviarlo a la red. Es por eso que pequeños sistemas de generación distribuida, tales como el SGFV que se desea caracterizar necesitan un convertidor CD-CA como una interfaz entre la fuente de generación (paneles fotovoltaicos) y las cargas, además de la red de distribución. Debido a la variabilidad de la

fuente primaria de energía, los inversores conectados a un SGFV normalmente experimentan una variación considerable de tensión en su entrada, lo que provoca la necesidad de distintas topologías y controles en los inversores. De manera resumida, a continuación se listan las capacidades básicas que debe tener un inversor conectado a un SGFV [X. Yaosuo04].

- Conversión de potencia de un voltaje variable de CD para sistemas aislados de la red, o una corriente de salida de CA que siga el voltaje y la frecuencia de la red para sistemas interconectados a la red.
- Buena calidad de la energía, es decir, una potencia de salida con un valor mínimo de distorsión armónica total (THD), desviaciones de voltaje y frecuencia así como variaciones de tensión o flickers.
- Sistemas de protecciones desde los arreglos fotovoltaicos, así como hacia la red.

Como el objetivo de esta tesis es desarrollar una metodología de caracterización generalizada, el inversor se caracterizara con una RNA. El único parámetro caracterizado será el de la eficiencia, para poder obtener el valor de potencia de CA que es inyectado a la red eléctrica.

3.5.1. Descripción y validación de la RNA propuesta para el inversor

Para caracterizar el inversor, no se requiere de una RNA tan compleja, ya que como única entrada, tendrá la potencia de CD, y como única salida, la de CA, así pues, se propuso una RNA con una sola capa oculta, con dos neuronas en ella, con la función de transferencia sigmooidal simétrica de Elliot, la función de entrenamiento utilizada fue la función *trainlm*.

La Figura 3.15 muestra la potencia de CA real comparada con la obtenida por la RNA. Al igual que en la caracterización del arreglo fotovoltaico, se espera que contar con mas datos de entrenamiento mejore sustancialmente el resultado.




Figura 3.15: Potencia de CA real comparada con la obtenida por la RNA

3.6. Conclusiones del capítulo

Como se puede observar por los resultados obtenidos en este capítulo, la caracterización de un arreglo fotovoltaico mediante la implementación de RNA's resulta bastante adecuado, ya que, como se mencionó anteriormente, no importa la tecnología de fabricación de las celdas de los paneles, el tipo de instalación de los paneles (fija o movable), el clima del lugar donde están instalados, la capacidad del arreglo o el tipo de inversor que se use, las RNA's propuestas podrán ser implementadas, siempre y cuando se cuente con la base de datos necesaria para realizar el entrenamiento.

Capítulo 4

Casos de Estudio

En el Capítulo 2 de esta tesis, se creó un sistema predictor de condiciones meteorológicas basado en RNA's, proponiéndose tres métodos para realizar la predicción. En el Capítulo 3 se caracterizó uno de los tres arreglos fotovoltaicos del SGFV instalado en la DEP-FIE utilizando RNA's. En este capítulo, se unificaran ambos sistemas, de manera que sea posible predecir la potencia de CA a la salida del arreglo fotovoltaico.

Se escogieron los días 13, 14 y 15 del mes de Febrero del año en curso para realizar el pronóstico de la potencia de CA entregada por el arreglo fotovoltaico a la salida del inversor, una vez más, los resultados fueron comparados con mediciones reales, y se observó su desempeño observando el RMSE.

4.1. Predicción de h días en adelante

Para el pronóstico de la potencia, es necesario primero realizar el pronóstico de las condiciones meteorológicas que se presentaron este día y que influirán directamente en la generación de potencia, es decir la irradiancia solar y la temperatura de la celda. Con esto en mente, se realizó el pronóstico de estas variables utilizando los tres métodos presentados en el Capítulo 2, es decir, predicción de una hora en adelante, un día en adelante y h días en adelante.

Como se explicó en el Capítulo 2, este método consiste en predecir las condiciones meteorológicas de un día específico, utilizando mediciones históricas. Es necesario que la base

de datos utilizada para el entrenamiento consista de al menos un año de mediciones para dar la ventana de predicción de un año deseada. En este caso específico, se contó con mediciones de parte del 2013, 2014 y 2015. La Figura 4.1 muestra la irradiancia y la temperatura ambiente pronosticadas para el día 13 de Febrero.

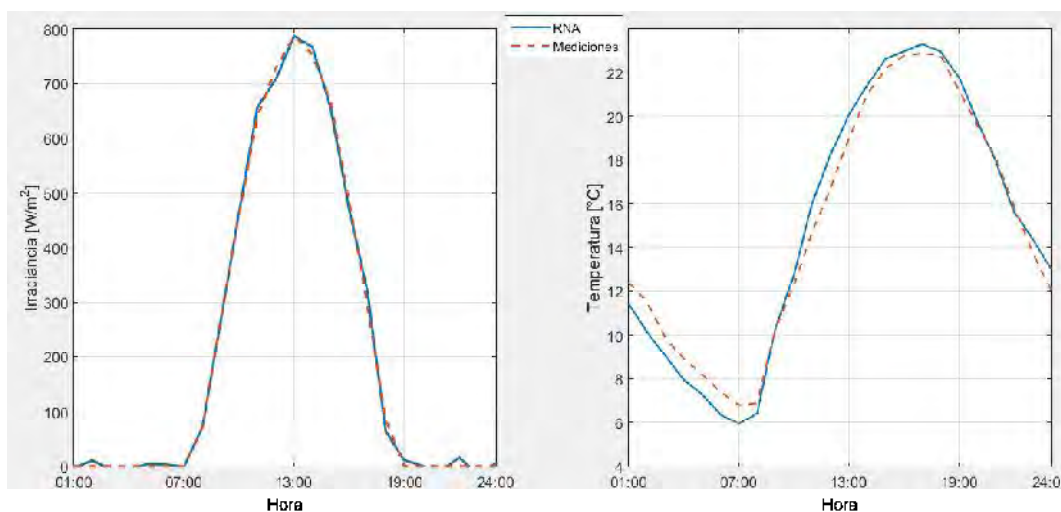


Figura 4.1: Condiciones meteorológicas pronosticadas para el día 13 de Febrero

En la Figura 4.1, a la izquierda, se observa la irradiancia medida (línea punteada) y la pronosticada (línea sólida), y a la derecha, la temperatura ambiente medida (línea punteada), contra la pronosticada (línea sólida). Como se puede observar, la curva de irradiancia no presenta cambios repentinos en su magnitud, esto quiere decir que no hubo interferencia nubosa significativa. En la Figura 4.2 se puede observar la potencia de CA obtenida con la caracterización realizada en el Capítulo 3 comparada con la medida a la salida del inversor del arreglo fotovoltaico.

Se puede observar que si bien la predicción de la irradiancia fue muy buena, existen desviaciones entre la temperatura ambiente real y la pronosticada, lo que provoca que la predicción de la potencia de salida tenga una desviación con respecto de la real.

La Figura 4.3 muestra las condiciones meteorológicas pronosticadas para el día 14 de Febrero.

Como se puede observar, el sistema predictor pronosticó una irradiancia pico me-




Figura 4.2: Potencia de CA real y pronosticada para el 13 de Febrero




Figura 4.3: Condiciones meteorológicas pronosticadas para el día 14 de Febrero

nor a la real. Esto se debe a que en alguno de los días que se utilizó como entrenamiento, muy probablemente se presentó un día parcialmente nublado, provocando que el promedio de la irradiancia incidente bajaría, sin embargo, pronóstico de muy buena manera la temperatura ambiente en las horas sol, y ya que la temperatura de la celda está en función de la irradiancia, la potencia de CA pronosticada no presenta una variación tan significativa, como se muestra en la Figura 4.4.




Figura 4.4: Potencia de CA real y pronosticada para el 14 de Febrero

En la Figura 4.5 se observan las condiciones meteorológicas pronosticadas para el día 15 de Febrero. Se observa claramente en la irradiancia medida, un cambio repentino en la magnitud de la misma, presente solamente en un instante de tiempo, esto quiere decir que una nube pasajera interfirió entre el sol y el arreglo fotovoltaico, sin embargo, en las mediciones pasadas esto no ocurrió, por lo que la RNA entregó resultados como si se tratase de un día completamente despejado. Esto, resulta de bastante utilidad para evidenciar la problemática de la predicción con una ventana de tiempo tan grande. En la Figura 4.6 se observa la potencia de CA real contra la medida, observándose ahí también la diferencia del pronóstico y la realidad durante el instante de tiempo en el que la nube interfirió.




Figura 4.5: Condiciones meteorológicas pronosticadas para el día 15 de Febrero




Figura 4.6: Potencia de CA real y pronosticada para el 15 de Febrero

4.2. Predicción con 24 horas de adelanto

En caso de que no se cuente con la base de datos necesaria para realizar la predicción con el método anterior, se puede optar por predecir únicamente 24 horas en adelanto, ya que únicamente ocupa de las mediciones meteorológicas de dos días anteriores al que se quiere predecir. La Figura 4.7 muestra las condiciones meteorológicas y la Figura 4.8 la potencia de CA pronosticadas utilizando este método para el día 13 de Febrero.




Figura 4.7: Condiciones meteorológicas pronosticadas para el día 13 de Febrero

Como se puede observar, la desviación entre el pronóstico y los valores reales es bastante significativo, esto, por que alguno de los dos días (o ambos) presentaron una masa nubosa significativa, por lo que la RNA, al entrenarse con valores promedios de estos dos días, entrega valores por debajo de los reales.

En la Figura 4.9 se observan los resultados del pronóstico de las condiciones meteorológicas del día 14 de Febrero, en la cual se puede observar que si bien la predicción de la irradiancia tuvo una desviación mínima, la predicción de la temperatura durante las horas sol tuvo una desviación significativa, lo cual evitó que la predicción de la potencia fuera tan buena como la de la irradiancia, sin embargo, los resultados obtenidos son bastante aproximados a las mediciones reales, como se puede observar en la Figura 4.10.




Figura 4.8: Potencia de CA real y pronosticada para el 13 de Febrero




Figura 4.9: Condiciones meteorológicas pronosticadas para el día 14 de Febrero




Figura 4.10: Potencia de CA real y pronosticada para el 14 de Febrero

En el caso del día 15, ocurre lo contrario al día 13, ya que los dos días utilizados para el entrenamiento de la red fueron días soleados, y el día que se pronosticó tuvo una interferencia nubosa, lo que da como resultado una desviación tanto en la irradiancia como en la temperatura en las horas sol pronosticada, como se observa en la Figura 4.11. Así que es de esperarse, que la potencia de CA pronosticada tenga aun más desviación, gracias al pronóstico errado de la irradiancia y la temperatura, esto se observa en la Figura 4.12, la cual muestra que la potencia pronosticada presenta desviaciones significativas contra la potencia de CA real.

4.3. Predicción con 1 hora de adelanto

Si se desea realizar una predicción de una ventana de tiempo muy corta (1 hora), se le puede dar el enfoque utilizado en ese método, el cual, como se mencionó en el Capítulo 2, hace uso de la totalidad de la base de datos para dar la mejor predicción del instante siguiente. Las Figuras 4.13, 4.15 y 4.17 muestran las condiciones meteorológicas pronosticadas para los días 13, 14 y 15 de Febrero respectivamente. Se observa un excelente desempeño, principalmente en la predicción de la temperatura, sin embargo, en el día donde existió la presencia de nubes, manda resultados erróneos, aun así, representa la mejor opción




Figura 4.11: Condiciones meteorológicas pronosticadas para el día 15 de Febrero

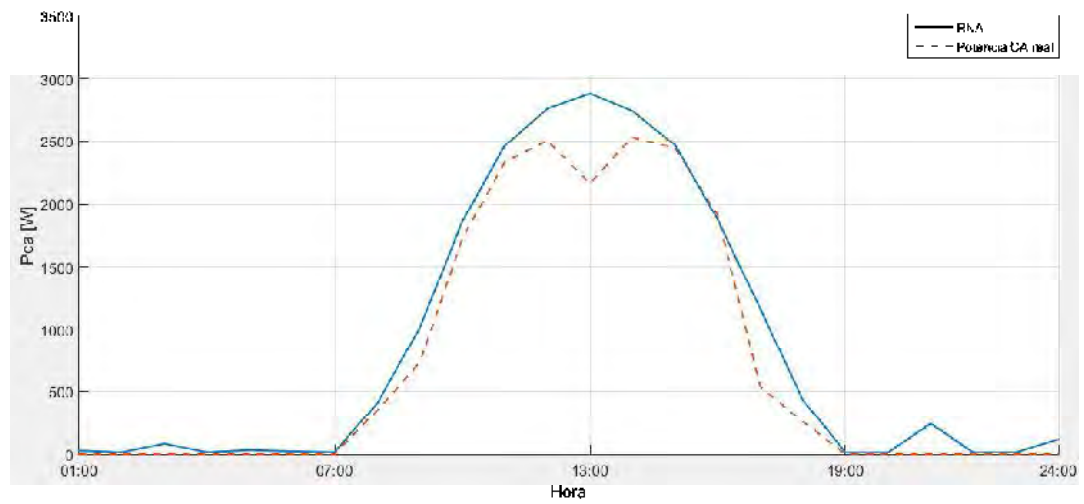


Figura 4.12: Potencia de CA real y pronosticada para el 14 de Febrero

para realizar la predicción en días nublados, pues al no basar su entrenamiento en promedios de días anteriores, sino en las condiciones meteorológicas presentes un instante antes del que se quiere predecir, puede, con una exactitud razonable, predecir la interferencia nublada entre el sol y el SGFV, pudiendo así también, obtener una potencia de CA más cercana a la real. Las Figuras 4.14 4.16 4.18 muestran las potencias de salida de los días 13, 14 y 15 de Febrero respectivamente




Figura 4.13: Condiciones meteorológicas pronosticadas para el día 13 de Febrero

En la Tabla 4.1 se muestra el RMSE de cada uno de los métodos para la predicción de G , T_a y P_{ca} .

Tabla 4.1: Tabla comparativa del RMSE para G , T_a y P_{ca} usando los tres métodos de predicción

Método	13/02/16			14/02/16			15/02/16		
	G	T_a	P_{ca}	G	T_a	P_{ca}	G	T_a	P_{ca}
Largo plazo	11.7410	0.7934	86.6579	14.5355	0.8168	61.6790	46.1465	1.1326	144.7687
Mediano Plazo	58.7894	1.4194	239.1735	15.3394	1.5413	65.1252	99.4379	1.8055	228.5672
Corto plazo	24.9432	0.2533	71.1884	18.7316	0.2630	67.4833	56.0713	0.3246	161.1117

Como se puede observar, contrario a lo esperado, el método que tuvo mejor desempeño es el método de predicción a largo plazo. Esto se debe a que las condiciones meteo-




Figura 4.14: Potencia de CA real y pronosticada para el 13 de Febrero




Figura 4.15: Condiciones meteorológicas pronosticadas para el día 14 de Febrero




Figura 4.16: Potencia de CA real y pronosticada para el 14 de Febrero




Figura 4.17: Condiciones meteorológicas pronosticadas para el día 15 de Febrero




Figura 4.18: Potencia de CA real y pronosticada para el 15 de Febrero

rológicas presentes en el día que se pronosticó, coincidieron en gran medida a las presentes en ese mismo día, en años anteriores, los cuales se utilizaron para entrenar las RNA's.

Como un caso de estudio adicional, se realizaron las predicción de potencia de CA para los días 2, 3 y 4 de abril del año 2016, debido a que el horizonte de tiempo para esta predicción es tan amplia, el único método aplicable es el de predicción a largo plazo. Como se observa en la Figura 4.19 la irradiancia pronosticada para los días propuestos, no presenta una gran cantidad de interferencia nubosa, por lo que se espera que las predicciones tengan una buena precisión. En la Figura 4.20 podemos observar la potencia de CA pronosticada para los días propuestos.

La razón de realizar este último estudio, es para demostrar que la metodología propuesta pueda servir como base para realizar estudios y proyecciones de las condiciones en las que operara el SGFV en los días pronosticados, de manera que se puedan considerar para los análisis de operación de la red eléctrica en esos mismos días.

4.4. Conclusiones del capítulo

Como se pudo observar en los casos de estudio presentados en este capítulo, la predicción a corto plazo es la más precisa, lo que la hace una herramienta que pudiera




Figura 4.19: Irradiancia y Temperatura ambiente pronosticados para los días 2,3 y 4 de Abril del 2016




Figura 4.20: Potencia de CA para los días 2, 3 y 4 de Abril del 2016

ser de utilidad con la inclusión del nuevo esquema del mercado energético en México; sin embargo, los otros dos métodos aun representan también buenas alternativas en caso de que no se cuente con el equipo necesario para estar tomando mediciones en tiempo real, necesarias para la implementación del método de corto plazo.

En algunos de los casos de estudio presentados, en las predicciones se presentan niveles de irradiación mayores a cero durante horas de la noche. Esto es por el como fueron entrenadas las RNA's, pues al ser entrenadas con mediciones reales, existen niveles de irradiancia bajos en los datos de entrenamiento, en estos casos, las RNA propuestas no son capaces de distinguir los valores cero de valores muy pequeños.

Capítulo 5

Conclusiones y Trabajos Futuros

Esta tesis, fue dividida en tres grandes bloques, en los cuales se propusieron metodologías y se realizaron estudios. Estas metodologías buscan ofrecer un nuevo enfoque que ayude al mejor entendimiento y aprovechamiento del recurso solar, utilizando tecnología fotovoltaica. En el primer bloque, se aborda el que quizás sea el mayor reto actualmente en la explotación de la energía proveniente del sol, la predicción de la irradiancia y de la temperatura ambiente. De este bloque, las conclusiones más relevantes son las siguientes:

- Como se observó en el Capítulo 2, la mayoría de las veces, mientras menor sea la ventana de predicción, mejores serán los resultados. Sin embargo, esto no siempre es correcto, ya que el desempeño del predictor va ligado al tamaño y a la calidad de la base de datos que se use para entrenar las RNA's.
- La correcta selección de la arquitectura de las RNA a implementar debe ser analizada cuidadosamente, pues, el objetivo principal, es ofrecer una metodología de predicción generalizada y que sea capaz de funcionar sin importar el nivel de variabilidad que se presente en la climatología del lugar donde se quiera implementar.
- La combinación de métodos estadísticos con técnicas de inteligencia artificial, pueden mejorar significativamente la precisión de las técnicas de predicción, como se observó en la predicción de una hora en adelante, en la cual, el filtrado de los datos de entrenamiento de las RNA's se realiza mediante la implementación de una técnica

muy similar a la de vecinos cercanos, mejorando notablemente su desempeño .

- La predicción de la climatología relevante para un SGFV sigue siendo un gran reto, ya que, hasta la fecha, no se ha logrado obtener un desempeño 100 por ciento confiable, sin embargo, con la implementación de las técnicas adecuadas, se puede lograr reducir el nivel de incertidumbre a un nivel mínimo, el cual, debido a la poca penetración de la generación fotovoltaica en la actualidad, es tolerable, sin embargo, en el futuro a mediano plazo, se espera que la penetración de la generación fotovoltaica en los sistemas de potencia aumente significativamente, por lo que el refinamiento de las técnicas de predicción, al menos las técnicas con ventanas de predicción de corto y mediano alcance se hace vital.

El siguiente bloque que se analizó fue el de los paneles fotovoltaicos. Actualmente, la tecnología presente en la fabricación de los mismos está cambiando aceleradamente, esto, buscando la obtención de una mejor eficiencia en la conversión de la energía solar en energía eléctrica, una mayor vida útil y una reducción en los costos de fabricación. Las conclusiones a las que se llegaron en cuanto a este tema son las siguientes:

- La caracterización de paneles fotovoltaicos mediante RNA's resulta muy ventajosa, pues, si se cuentan con los datos suficientes para realizar el entrenamiento, se podrá caracterizar un solo panel, o un arreglo de paneles, sin importar la combinación de conexiones serie-paralelo que existan en el arreglo, no importando además, la capacidad de generación que tenga el panel o el arreglo.
- Otra gran ventaja de las RNA's utilizadas para la caracterización de paneles fotovoltaicos, es el hecho de que observan indirectamente cierto tipo de pérdidas que los modelos matemáticos discriminan, tales como el polvo e la superficie y las pérdidas ohmicas por el cableado interno, que si bien en un solo panel quizás sean despreciables, cuando se habla de una granja de capacidad considerable, estas pérdidas pueden ser significativas, por lo que es importante su análisis.
- Es de suma importancia, que las mediciones que se utilizan para el entrenamiento de las RNA's sean tomadas con instrumentos que ofrezcan una alta precisión en el sensado

de las mismas, pues, de no hacerse así, la caracterización del panel, no podrá ofrecer los resultados esperados.

Finalmente, el último bloque analizado conjunta el sistema predictor y el arreglo fotovoltaico caracterizado, esto, con el objetivo de poder pronosticar la potencia de salida de un SGFV. Las conclusiones a las que se llegaron respecto a este tema son las siguientes:

- El ser capaz de predecir la potencia de salida de un SGFV de gran capacidad sería de gran utilidad ya que estos tienen una influencia considerable en la operación de la red eléctrica y como se observó en la realización de esta tesis la alta variabilidad de las condiciones climáticas influyen directamente en la potencia de salida de un SGFV, lo que pueden llevar a condiciones no deseables en la red.
- Para el correcto pronóstico de la potencia de salida de un SGFV, se requieren de datos altamente confiables y con una muy buena calidad en el proceso de medición, es deseable que exista un grado de redundancia en las mediciones obtenidas, para disminuir el grado de incertidumbre presente en las predicciones.
- Si bien los resultados obtenidos en esta tesis son bastante alentadores, se reconoce que aun existen áreas de oportunidad para aumentar la precisión del pronóstico de la potencia de salida de un SGFV.

5.1. Trabajos futuros

El desarrollo de esta tesis puede ser ampliado tomando en cuenta los siguientes tópicos:

- Si bien la predicción con una hora en adelante cuenta con una etapa de filtrado de datos que utiliza un algoritmo similar al de vecinos cercanos, aun cuenta con cierto tipo de errores, el más significativo es cuando detecta condiciones meteorológicas similares al del instante $h-1$ en la base de datos, pero lo interpreta de forma errónea, es decir, si el siguiente punto es de una irradiación mayor, puede que el filtrado de datos lo interprete como si el siguiente punto es de una irradiación menor. Esto se puede solucionar

adicionando una condicional que tome en cuenta la pendiente que lleva la curva de la irradiación, si la pendiente es positiva, que solo tome valores correspondientes a una irradiación mayor en el entrenamiento, y si es negativa, que solo tome valores con una magnitud de irradiación menor.

- Los métodos de predicción de 24 horas en adelante y de h días en adelante, son basados al 100 % en RNA's, se espera que con la combinación de técnicas estadísticas para el filtrado de datos, los resultados obtenidos mejoren.
- Con la disposición de más datos para el entrenamiento de las RNA's de la caracterización del arreglo fotovoltaico, se esperaría tener un mejor resultado en la potencia obtenida por la caracterización, además, se debería de entrenar a las RNA's con datos correspondientes a las 4 estaciones del año, de manera que la caracterización pueda arrojar resultados confiables, sin importar la fecha en la que se desea obtener la potencia de salida.
- Las metodologías desarrolladas pueden ampliarse para representar la operación del SGFV operando interconectado a la red.
- El horizonte temporal de predicción puede ajustarse para que coincida con las ventanas de pronóstico definidas para la operación del mercado eléctrico, de manera que se puedan utilizar como herramienta en la toma de decisiones por parte de los participantes del mercado.

Apéndice A

Extracto de Datos Tomados con la Estación Meteorológica

Tabla A.1: Extracto de datos obtenidos con la estación meteorológica *Vantage Pro 2*.

Fecha	Hora	Hum.	Vel.	Sens.	Índice THSW	Pres.	Dens.	T_a	G
05/03/2015	05:30 a. m.	75	0	10.7	8.4	757.8	1.2038	10.7	0
05/03/2015	05:40 a. m.	75	0.4	10.6	8.3	757.9	1.2041	10.6	0
05/03/2015	05:50 a. m.	75	0.4	10.6	8.2	758	1.204	10.6	0
05/03/2015	06:00 a. m.	74	0	10.7	8.3	758.1	1.2048	10.7	0
05/03/2015	06:10 a. m.	74	0	10.8	8.4	758.1	1.2053	10.8	5
05/03/2015	06:20 a. m.	73	0	10.9	8.7	758.2	1.2058	10.9	17
05/03/2015	06:30 a. m.	72	0.4	11.3	9.3	758.1	1.206	11.3	32
05/03/2015	06:40 a. m.	70	0	11.8	10	758.1	1.2062	11.8	55
05/03/2015	06:50 a. m.	67	0	12.3	10.8	758.2	1.2064	12.3	84
05/03/2015	07:00 a. m.	68	0	12.7	11.6	758.3	1.2066	12.7	118
05/03/2015	07:10 a. m.	67	0.4	13	12.3	758.3	1.2066	13	153
05/03/2015	07:20 a. m.	65	0.4	13.3	13.1	758.2	1.206	13.3	188
05/03/2015	07:30 a. m.	65	0	13.6	13.8	758.3	1.2057	13.6	224
05/03/2015	07:40 a. m.	65	0	13.8	17	758.3	1.2057	13.8	260
05/03/2015	07:50 a. m.	63	0.9	14.3	17.9	758.6	1.206	14.3	298
05/03/2015	08:00 a. m.	62	0.4	14.8	18.9	758.7	1.2055	14.8	339
05/03/2015	08:10 a. m.	59	0	15.5	19.9	758.8	1.2049	15.5	373
05/03/2015	08:20 a. m.	57	0	16.3	21	758.7	1.2045	16.3	413
05/03/2015	08:30 a. m.	52	0	17.4	22.6	758.7	1.2039	17.4	471
05/03/2015	08:40 a. m.	48	0	18.4	23.1	758.7	1.2039	18.4	478
05/03/2015	08:50 a. m.	47	0.9	18.3	22.8	758.7	1.2031	18.3	505
05/03/2015	09:00 a. m.	46	0.9	18.6	23.1	758.7	1.2025	18.6	542
05/03/2015	09:10 a. m.	45	1.8	19.1	23.6	759	1.2022	19.1	570
05/03/2015	09:20 a. m.	44	1.8	19.3	23.7	759.1	1.202	19.3	592
05/03/2015	09:30 a. m.	42	0.9	20.3	24.6	758.9	1.2009	20.3	623
05/03/2015	09:40 a. m.	40	2.2	20.7	24.9	758.7	1.2003	20.7	664
05/03/2015	09:50 a. m.	40	1.3	21.1	25.1	758.6	1.199	21.1	686
05/03/2015	10:00 a. m.	38	2.2	21.6	23.8	758.6	1.199	21.6	392
05/03/2015	10:10 a. m.	37	1.8	21.8	23.7	758.4	1.1976	21.8	349
05/03/2015	10:20 a. m.	33	2.7	22.1	25.5	758.2	1.197	22.1	609
05/03/2015	10:30 a. m.	34	2.7	22.2	24.4	758.1	1.1965	22.2	413

Referencias

- [A. K. Yadav14] A. K. Yadav, H. M. Selection of most relevant input parameters using weka for artificial neural network based solar radiation prediction models. *Renewable and sustainable energy reviews*, 31:509–519, 2014.
- [A. Kumar14] A. Kumar, S. C. Solar radiation prediction using artificial neural network techniques: A review. *Renewable and Sustainable Energy Reviews*, 33:772–781, 2014.
- [A. Mellit13] A. Mellit, S. K., S. Saglam. Artificial neural network-based model for estimating the produced power of a photovoltaic module. *Renewable Energy*, 60:71–78, 2013.
- [A. Moreno-Muñoz08] A. Moreno-Muñoz, R. P., G. de la Rosa. Short term forecasting of solar radiation. *IEEE International Symposium on Industrial Electronics*, págs. 1537–1541, 2008.
- [A. Ndiaye13] A. Ndiaye, C. K. Impact of dust on the photovoltaic (pv) modules characteristics after an exposition year in sahelian environment: The case of senegal. *International Journal of Physical Sciences*, 8:1166–1173, 2013.
- [A. Suratgar07] A. Suratgar, A. H., M. Bagher. Modified levenberg marquardt method for neural networks. *International Journal of Computer, Electrical, Automation, Control and Information Engineering*, 16:1447–1461, 2007.

- [Armas09] Armas, M. D. Fundamentos básicos de inteligencia artificial con matlab. 2009.
- [Atiya91] Atiya, A. Learning algorithms for neural networks. *California Institute of Technology*, 1, 1991.
- [Beale72] Beale, E. A derivation of conjugate gradients. *Numerical methods for nonlinear optimization*, 8, 1972.
- [Bermejo01] Bermejo, S. Oriented principal component analysis for large margin classifiers. *Neural Networks*, 14:1447–1461, 2001.
- [Boxwell12] Boxwell, M. Solar electricity handbook: A simple, practical guide to solar energy. págs. 41–42, 2012.
- [Buresch83] Buresch, M. Photovoltaic energy systems: design and installation. 1983.
- [Corning10] Corning, D. The science of solar: Solar energy- the basics. *Dow Corning Solar Solutions*, <http://dowcorning.com/solar>, 2010.
- [D. Sera07] D. Sera, T. P. R., R. Pv panel model based on datasheet values. *IEEE International Symposium on Industrial Electronics*, págs. 2392–2396, 2007.
- [E. Lorenz09] E. Lorenz, D. H., J. Hurka. Irradiance forecasting for the power prediction of grid-connected photovoltaic systems. *IEEE Journal of selected topics en applied earth observations and remote sensing*, 2, 2009.
- [E. Moreira95] E. Moreira, E. F. Neural networks with adaptive learning rate and momentum terms. *Institut Dalle Molle D?Intelligence Artificielle Perceptive*, págs. 94–105, 1995.
- [F. Wang12] F. Wang, S. S., Z. Mi. Short-term solar irradiance forecasting model

- based on artificial neural network using statistical feature parameters. *Energies*, 5:1355–1370, 2012.
- [Fisher20] Fisher, R. Mathematical examination of the methods of determining the accuracy of an observation by the mean error and by the mean square error. *Monthly Notices of the Royal Astronomical Society*, 80:758–770, 1920.
- [FSEC10] FSEC. *Test Method for Photovoltaic Module Power Rating*. Florida Solar Energy Center, 2010.
- [G. Almonacid10] G. Almonacid, P. P.-H. L. H., C. Rus. Calculation of the energy provided by a pv generator. comparative study: Conventional methods vs artificial neural networks. *Energy*, 36:375–384, 2010.
- [G. Araujo82a] G. Araujo, M. M., E. Sánchez. Determination of the two-exponential solar cell equation parameters from empirical data. *Solar Cells*, 5:199–204, 1982.
- [G. Araujo82b] G. Araujo, M. M., Sánchez. E. Determination of the two-exponential solar cell equation parameters from empirical data. *Solar Cells*, págs. 199–204, 1982.
- [G. Carpenter91] G. Carpenter, S. G. Artmap: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network. *Neural Networks*, 4:565–588, 1991.
- [G. Tiwari10] G. Tiwari, D. D. Fundamentals of photovoltaic modules and their applications. *International Conference on Renewable Energy and Power Quality*, 2, 2010.
- [G. Towell94] G. Towell, J. S. Knowledge-based artificial neural networks. *Artificial Intelligence*, 70, 1994.
- [Gluskoter02] Gluskoter, H. World fossil fuel reserves and projected depletion. 2002.

- [Gylfason00] Gylfason, T. Natural resources, education and economic development. *CEPR Discussion Paper*, 2594, 2000.
- [H. Maimouna13] H. Maimouna, P. L., D. Mathieu. Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. *Renewable and Sustainable Energy Reviews*, 27:65–76, 2013.
- [H. Steinherz01] H. Steinherz, C. P. Neural networks for short-term load forecasting: A review and evaluation. *IEEE Transactions on power systems*, 16:993–1001, 2001.
- [I. Basheer00] I. Basheer, M. H. Artificial neural networks: fundamentals, computing, design, and application. *Neural Computing in Microbiology*, 43:3–31, 2000.
- [I. Ceylan14] I. Ceylan, E. G.-A. E.-G., O. ErKaymaz. The prediction of photovoltaic module temperature with artificial neural networks. *Case Studies in Thermal Engineering*, 3:11–20, 2014.
- [I. Sansa14] I. Sansa, Z. M. Pv power forecasting using different artificial neural networks strategies. *IEEE transactions on First International Conference on Green Energy ICGE*, 2014.
- [J. Sánchez15] J. Sánchez, R. T., E. Espinosa. Photovoltaic panel characterization by using artificial neural networks and comparison with classical models. *IEEE International Autumn Meeting on Power, Electronics and Computing*, 2015.
- [Jain96] Jain, A. Artificial neural networks: A tutorial. *Michigan State University*, 1996.
- [Jiang05] Jiang, J. Maximum power point tracking for photovoltaic power systems. *Tamkang Journal Science and Engineering*, 8:147–153, 2005.
- [K. Hansen90] K. Hansen, P. S. Neural networks ensembles. *IEEE Transactions on pattern analysis and machine intelligence*, 12:993–1001, 1990.

- [K. Mehrotra96] K. Mehrotra, K. M. Elements of artificial neural networks. 8:147–153, 1996.
- [Karatepe03] Karatepe, E. Estimation of equivalent circuit parameters of pv module using neural network. *Turkish Symposium on Artificial Intelligence and Neural Networks International XII*, 2003.
- [L. Cortez12] L. Cortez, G. A.-S. M. R. A. D. R., J.I. Cortez. Determination of the efficiency of a photovoltaic system operating on the climatic features of mexico. *International Journal of Advanced Renewable Energy Researches (IJARER)*, 1:203–206, 2012.
- [L. Sandrolini10] L. Sandrolini, U. R., M. Artioli. Numerical method for the extraction of photovoltaic module double-diode model parameters through cluster analysis. *Applied Energy*, 87:442–451, 2010.
- [Letendre14] Letendre, S. Predicting solar power production: Irradiance forecasting models, applications and future prospects. *Solar Electric Power Association*, 2014.
- [M. Hosenuzzaman15] M. Hosenuzzaman, N. R. Global prospects, progress, policies, and environmental impact of solar photovoltaic power generation. *Renewable and sustainable energy reviews*, 41:284–297, 2015.
- [M. Paulescu14] M. Paulescu, E. P., O. Mares. Nowcasting solar irradiance using the sunshine number. *Energy Conversion and Management*, 79:690–697, 2014.
- [Marquez12] Marquez, R. Solar irradiance forecasting at multiple time horizons and novel methods to evaluate uncertainty. *University of California*, 2012.
- [N. Karayiannis97] N. Karayiannis, G. W. Growing radial basis neural networks: Merging supervised and unsupervised learning with network growth techniques. *IEEE Transactions on Neural Networks*, 8, 1997.

- [Naci-Celik11] Naci-Celik, A. Artificial neural network modelling and experimental verification of the operating current of mono-crystalline photovoltaic modules. *Solar Energy*, 85:2507–2517, 2011.
- [Ogimoto10] Ogimoto, K. System wide issues related to massive penetration of pv in the electricity systems. *Collaborative Research Center for Energy Engineering (CCE)*, <http://iis.u-tokyo.ac.jp>, 2010.
- [Osterwald86] Osterwald, C. Translation of device performance measurements to reference conditions. *Solar Cells*, 18:269–279, 1986.
- [P. Bacher09] P. Bacher, H. N., H. Madsen. Online short-term solar power forecasting. *Solar Energy*, 2009.
- [Powell77] Powell, M. Restart procedures for the conjugate gradient method. *Mathematical Programming*, 12:241–254, 1977.
- [R. Iyer13] R. Iyer, M. B., V. Menon. The influence of synaptic weight distribution on neuronal population dynamics. *PLoS Computational Biology*, 9, 2013.
- [S. Lineykin12] S. Lineykin, A. K., M. Averbukh. Five-parameter model of photovoltaic cell based on stc data and dimensionless. *IEEE 27th Convention of Electrical and Electronics Engineers in Israel*, 2012.
- [S. Mekhilef14] S. Mekhilef, M. K., R. Saidurb. Effect of dust, humidity and air velocity on efficiency of photovoltaic cells. *Renewable and Sustainable Energy Reviews*, págs. 2920–2925, 2014.
- [S. Pelland11] S. Pelland, G. K., G. Galanis. Solar and photovoltaic forecasting through post-processing of the global environmental multiscale numerical weather prediction model. *Progress in Photovoltaics: Research and Applications*, 10, 2011.
- [S. Samkeliso15a] S. Samkeliso, H. M. Comparative analysis of different single-diode pv modeling methods. *IEEE journal of photovoltaics*, 5, 2015.

- [S. Samkeliso15b] S. Samkeliso, H. M. Comparative analysis of different single-diode pv modeling methods. *IEEE journal of photovoltaics*, 5, 2015.
- [S. Shafiee09] S. Shafiee, E. T. When will fossil fuel reserves be diminished? *Energy Policy*, 37:181–189, 2009.
- [S.A. Kalogirou14] S.A. Kalogirou, V. B., E. Mathioulakis. Artificial neural networks for the performance prediction of large solar systems. *Renewable Energy*, 63:90–97, 2014.
- [Shiwanda13] Shiwanda, P. A photovoltaic panel model in matlab/simulink. *Wroclaw University of Technology*, 2013.
- [Smil06] Smil, V. Energy at the crossroads. *Global Science Forum Conference on Scientific Challenges for Energy Research*, 2006.
- [Steadman79] Steadman, R. The assessment of sultriness, part ii: Effects of wind, extra radiation and barometric pressure on apparent temperature. *Journal of Applied Meteorology*, 1979.
- [X. Yaosuo04] X. Yaosuo, J. B. Topologies of single-phase inverters for small distributed power generators: An overview,. *IEEE Transactions on Power Electronics*, 19, 2004.
- [Xydis14] Xydis, G. The wind chill temperature effect on a large-scale pv plant?an exergy approach. *Renewable and sustainable energy reviews*, 8:1611–1624, 2014.
- [Y. Li15] Y. Li, C. Y., J. Xu. A study of photovoltaic power prediction. *Applied Mechanics and Materials*, 733:203–206, 2015.
- [Yun98] Yun, Y. A performance evaluation of neural network models in traffic volume forecasting. *Mathematical and computing modelling*, 27:293–310, 1998.