



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Maestría

Predicción de la capacidad de generación para
un sistema fotovoltaico

presentada por

Ing. Cristian Alexis Corona Morales

como requisito para la obtención del grado
de

**Maestría en Ciencias en Ingeniería
Electrónica**

Director de tesis

Dr. Carlos Daniel García Beltrán

Cuernavaca, Morelos, México. febrero de 2022.



Centro Nacional de Investigación y Desarrollo Tecnológico
Departamento de Ingeniería Electrónica

Cuernavaca,
Mor.,
No. de Oficio:
Asunto:

20/enero/2022

DIE/050/2022

Aceptación de documentos de
tesis

DR. Carlos Manuel Astorga Zaragoza
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial del C. Ing. Cristian Alexis Corona Morales, con número de control M19CE019 de la Maestría en Ciencias en Ingeniería Electrónica, le informamos que hemos revisado el trabajo de tesis profesional titulado "Predicción de la Capacidad de Generación para un Sistema Fotovoltaico" y hemos encontrado que se han realizado todas las correcciones y observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

DIRECTOR DE TESIS


Dr. Carlos Daniel García Beltrán
Doctor en Ciencias en Ingeniería
Electrónica
Cédula profesional 8699605

REVISOR 1


Dra. Gloria Lilia Osorio Gordillo
Doctor en Ciencias en Ingeniería
Electrónica
Cédula profesional 9968714

REVISOR 2


Dr. Gerardo Vicente Guerrero Ramírez
Doctor en Ingeniería
Cédula profesional 3431842

C.p. Lic. Silvia del Carmen Ortiz Fuentes- Jefa del Departamento de Servicios Escolares
Estudiante
Expediente

HEE/mrsr



Interior Internado Palmira S/N, Col. Palmira, C. P. 62490, Cuernavaca, Morelos
Tel. 01 (777) 3627770, ext. 2225, e-mail: die@cenidet.tecnm.mx tecnm.mx | cenidet.tecnm.mx



2022 Flores
Año de
Magón
PRESELECCIÓN DE LA REVOLUCIÓN MEXICANA



Cuernavaca, Mor.,

25/enero/2022

No. de Oficio:

SAC/16/2022

Asunto:

Autorización de
impresión de tesis

CRISTIAN ALEXIS CORONA MORALES
CANDIDATO AL GRADO DE MAESTRO EN CIENCIAS
EN INGENIERÍA ELECTRÓNICA
PRESENTE

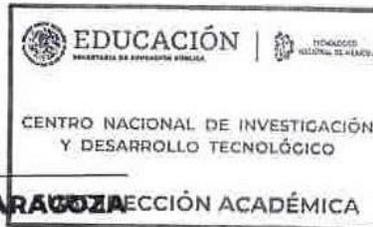
Por este conducto tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado "Predicción de la Capacidad de Generación para un Sistema Fotovoltaico", ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

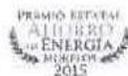
"Excelencia en Educación Tecnológica"

"Educación Tecnológica al Servicio de México"



DR. CARLOS MANUEL ASTORGA ZARAGOZA SUBDIRECCIÓN ACADÉMICA
SUBDIRECTOR ACADÉMICO

C.c.p. Lic. Silvia del Carmen Ortiz Fuentes, Jefa del Departamento de Servicios Escolares
Expediente
CMAZ/CHG



Resumen

Los sistemas fotovoltaicos son una fuente de generación con mayor accesibilidad, ya que su recurso primario es el sol y su instalación es generalmente sencilla; Sin embargo, conlleva ciertos factores que intervienen en el proceso y afectan considerablemente la producción. El factor más influyente son las condiciones climáticas, que a su vez también son afectadas por las estaciones del año. Uno de los factores que afectan directamente a la generación de energía a partir de sistemas fotovoltaicos son los cúmulos de nubosidad presentes a lo largo del día ya que estos intervienen de forma significativa entre la radiación y las celdas eléctricas obstruyendo de diversas formas el proceso de producción de energía.

Esta tesis busca predecir la capacidad de generación de energía fotovoltaica a partir de muestras reales y modelos matemáticos, para ello se hace uso de redes neuronales artificiales. Este método híbrido puede ser dividido en tres etapas, la primera, adquisición de datos de nubosidad de una zona seleccionada, en esta etapa se extraen imágenes satelitales del estado de nubosidad para después ser analizadas en escala de grises y proporcionar información a una primera red neuronal artificial, en la segunda etapa se realiza una predicción teórica de la irradiación solar sobre una superficie horizontal, estos datos no contienen elementos de nubosidad, por ello junto con los datos obtenidos de nubosidad y agregando la hora del día a cada dato son ingresados a una segunda red neuronal para poder realizar una predicción de irradiación solar sobre una superficie horizontal tomando en cuenta la nubosidad presente, finalmente en la tercera etapa se realizan el comportamiento de los datos predichos, haciendo uso de modelos matemáticos se obtiene la irradiación solar sobre una superficie inclinada, esta última obtenida de los datos predichos, posteriormente los datos son ingresados a un modelo matemático de panel solar y finalmente a un convertidor tipo boost, obteniendo así la energía generada en los próximos lapsos de tiempo.

Abstract

Photovoltaic systems are a source of electric energy with greater accessibility since their primary resource is the sun. Their installation is generally straightforward; however, it involves certain factors that intervene in the process and significantly affect energy production. The most influential factor is the climatic conditions, which at the same time are affected by the seasons of the year. One of the factors that directly affect the generation of energy from photovoltaic systems is the appearance of the cumulus clouds present throughout the day. These intervene significantly between the radiation and the electrical cells, obstructing the production process in various ways of energy.

This thesis proposes a strategy for predicting the photovoltaic energy generation capacity from actual data mathematical models and artificial neural networks. This hybrid method can be divided into three stages; the first is to acquire data from a selected area when the cumulus clouds are present; in this stage, satellite images of the cloudiness state are extracted to be later analyzed in grayscale provide information to a first artificial neural network. In the second stage, a theoretical prediction of solar irradiation on a horizontal surface is calculated; these data do not contain elements of cloudiness. Therefore, together with the cloudiness data obtained and adding the time of day to each data, they are entered into a second artificial neural network to predict solar irradiation on a horizontal surface, taking into account the presence of the cumulus clouds. Finally, in the third stage, the behavior of the predicted data is carried out, using mathematical models of the solar irradiation on an inclined surface. Later, predicted irradiation data and the mathematical model of a photovoltaic panel connected to boost dc/dc converter to forecast the electric energy in the following hours.

Dedicatoria

“Dedico esta tesis con gran amor y cariño a todas las personas involucradas en este proceso, mi familia, mi novia y mis amigos los cuales siempre me dieron su apoyo incondicional y ánimos de seguir adelante”.

Agradecimientos

A mi abuela Cristina Jiménez Castillo, quien siempre me brindó todo su amor, cariño y motivó cada uno de mis sueños e ilusiones.

A mis padres Cristina Lorena Morales Jiménez y Alejandro Corona Marquina quienes siempre impulsaron mi desarrollo académico y apoyaron en cada una de las decisiones que tome por muy difíciles que parezcan.

A mis hermanos Alejandro y Axel Corona Morales quienes alentaron cada uno de los procesos y situaciones en las que me encontré.

A mi novia y prometida Andrea Roxana Arias Rivera por su amor incondicional su enorme apoyo y comprensión durante todo este proceso.

A mis compañeros de clases Ángel Guadarrama, Zuleyma España y Germán Vázquez quienes fueron mis aliados durante todo este proceso, por su enorme apoyo, aliento, ánimos y amistad.

A mis revisores: Dr. Gloria Lilia Osorio Gordillo y el Dr. Gerardo Vicente Guerrero Ramírez, por sus siempre objetivas y acertadas observaciones las cuales ayudaron a la consolidación de esta tesis.

A mis profesores que fueron parte en mi formación académica, Dr. Gloria Osorio, Dr. Juan Reyes, Dr. Carlos Aztorga, Dr. Juan Reyes, Dr. Adam Medina, Dr. Víctor Alvarado y Guadalupe Madrigal.

Al Consejo Nacional de ciencia y Tecnología (CONACYT) por el apoyo económico brindado para durante este periodo para poder culminar mis estudios. Así como al CENIDET por permitirme integrar a su línea estudiantil, así como sus instalaciones.

A Dios por ser siempre mi fortaleza.

TABLA DE CONTENIDO

Introducción	1
1.1. Problemática de investigación	2
1.2. Estado del arte	3
1.3. Planteamiento del problema	7
1.4. Propuesta de solución	7
1.5. Objetivos	9
1.5.1. Objetivo general	9
1.5.2. Objetivos específicos	9
1.6. Metas	10
1.7. Justificación	10
1.8. Organización del documento	11
Modelos de irradiación teórica.....	12
2.1. Irradiación solar	12
2.1.1. irradiación solar global hora a hora en superficies horizontales (I_H)	12
2.1.2. Radiación difusa por hora en superficie horizontal (I_d)	13
2.1.3. Radiación directa por hora en superficie horizontal (I_b)	13
2.2.1. irradiación solar global hora a hora en superficies inclinadas (G)	13
2.2.2. Radiación difusa por hora en superficie inclinada ($I_d\beta$)	13
2.2.3. Radiación directa sobre una superficie inclinada ($I_d\beta$)	14
2.2.4. Radiación reflejada en superficie inclinada (I_r)	15
2.3.1. Desarrollo del modelo de irradiación solar sobre una superficie horizontal (I_H)	15
2.4 Desarrollo del modelo de irradiación solar sobre una superficie inclinada (G)	22
Modelos de generación, panel y convertidor	26
3.1. Sistemas fotovoltaicos	26

3.2. Factores que afectan la generación de energía	27
3.3. Celda solar	27
3.4. Modelos de celda fotovoltaica	28
3.5.2. Modelo matemático de panel fotovoltaico	30
3.5. Convertidor boost	31
3.6. Máximo punto de potencia	33
3.7. Algoritmos de MPPT seleccionados	34
Nubosidad y predicción de nubosidad con ANN.....	36
4.1 Nubosidad	36
4.4. Imágenes satelitales	37
4.5. Teledetección de nubosidad	37
4.7. Redes neuronales	40
4.7.1. Neurona artificial	41
4.7.2. Redes neuronales artificiales y cómo funcionan	42
4.7.3. Tipos de redes Neuronales artificiales	43
4.7.4. Entrenamiento de una red neuronal artificial	43
Pruebas y resultados de predicción	46
5.1. Caso de estudio: Niveles de nubosidad e irradiación en coordenadas – Jiutepec Morelos 99.1587,18.8851	46
5.2. Limitaciones	47
5.3. Propuesta de solución para la predicción de nubosidad	47
5.4. Adquisición de datos y tratamiento de imágenes	47
5.5. Diseño de RNA de predicción	49
5.6. Aplicación del método de predicción de irradiación	51
5.7 Predicción de niveles de nubosidad	52
5.8. Predicción teórica de irradiación solar	60
5.10. Red neuronal artificial 2 (ANN2)	64
5.11. Corrección y estimación de irradiación solar	65
5.12. Diseño de RNA para corrección	66
5.13. Predicción de irradiación sobre una superficie inclinada (G)	68

5.14. Aplicación de Predicción en modelo de convertidor boost	69
5.15. Aplicación del método a diferentes estados de nubocidad	70
Conclusiones	74
6.1 Conclusiones	74
6.2. Aportaciones	74
6.3. Trabajos futuros	75
Bibliografía	76

Índice de tablas

Tabla 1. Resumen de estado del arte.....	6
Tabla 2. Coeficientes F_i, j	14
Tabla 4. Declinación solar.	16
Tabla 5. Valores constantes.	20
Tabla 6. Coeficientes para modelo de Pérez.	23
Tabla 7. Datos de Irradiación solar.	25
Tabla 9. Tabla de valores.	31
Tabla 3. Resumen de estado del arte.....	43
Tabla 8. Error Cuadrático Medio (ERM).....	59
Tabla 10. Tabla de irradiación global.	69

Índice de figuras

Figura 1. Diagrama general de aplicación	2
Figura 2. Aparición de cúmulos de nubosidad.....	3
Figura 3. Esquema de predicción.....	8
Figura 4. Esquema general.....	9
Figura 5. Simulación de declinación.....	16
Figura 6. Simulación ángulo hora.....	17
Figura 7. Simulación azimut solar.....	18
Figura 8. Simulación de zenit solar.....	39
Figura 9. Simulación de irradiación difusa.....	¡Error! Marcador no definido. 20
Figura 10. Simulación de irradiación directa.....	26
Figura 11. Simulación de irradiación global horizontal.....	28
Figura 12. Simulación de Irradiación difusa sobre una superficie inclinada.....	29
Figura 13. Simulación de irradiación directa sobre una superficie inclinada.....	29
Figura 14. Simulación de irradiación solar global inclinada.....	25
Figura 15. Esquema de elementos fotovoltaicos.....	26
Figura 16. Modelo ideal de diodo único.....	28
Figura 17. Modelo detallado de diodo único.....	29
Figura 18. Modelo de doble diodo.....	29
Figura 19. Circuito equivalente de celda solar.....	34
Figura 20. Circuito equivalente de convertidor tipo boost.....	32
Figura 21. Convertidor boost posición 1.....	32
Figura 22. Convertidor boost posición 2.....	33
Figura 23. Algoritmo MPPT.....	34
Figura 24. MPPT.....	35
Figura 25. I Algoritmo MPPT.....	35
Figura 26. Tipos de nubes.....	37
Figura 27. Imagen de radiación infrarroja.....	38
Figura 28. Imagen vapor de agua.....	39
Figura 29. Imagen visible.....	39
Figura 30. Neurona biológica.....	40
Figura 31. Red neuronal biológica y artificial.....	42
Figura 32. Red neuronal artificial feed forward.....	43
Figura 33. Zona de análisis.....	46
Figura 34. Cuadrante de análisis 1.....	48

Figura 35. Cuadrante de análisis 2.	48
Figura 36. Imagen descargada.	49
Figura 37. Imagen es escala de grises	49
Figura 38. Extracción de datos.....	49
Figura 39. Esquema de predicción.	50
Figura 40. Red neuronal 1	50
Figura 41. Predicciones a un paso (10 - 18 horas).....	52
Figura 42. Predicción a un paso (19:00 horas).....	53
Figura 43. Predicciones a múltiples pasos (10 - 18 horas).....	54
Figura 44. Predicción a múltiples pasos (19:00 horas).	54
Figura 45. Predicción 10:00.	54
Figura 46. Dato real 10:00	55
Figura 47. Predicción 11:00	56
Figura 48. Dato real 11:00	56
Figura 49. Predicción 12:00	57
Figura 50. Dato real 12:00	57
Figura 51. Predicción 13:00.....	58
Figura 52. Dato real 13:00.	58
Figura 53. Predicción 14:00.	59
Figura 54. Dato real 14:00	59
Figura 55. Irradiación 21 de junio.....	61
Figura 56. Irradiación 22 de junio.....	61
Figura 57. Irradiación 23 de junio.....	62
Figura 58. Irradiación 24 de junio.....	63
Figura 59. Irradiación 25 de junio.....	63
Figura 60. Irradiación 26 de junio.....	64
Figura 61. Corrección de irradiación solar.....	65
Figura 62. Predicción de irradiación solar..	66
Figura 63. Punto d extracción de datos	68
Figura 64. Esquema de irradiación solar horizontal.	66
Figura 65. Red neuronal 2.....	67
Figura 66. Irradiación solar inclinada predecida y teórica.....	¡Error! Marcador no definido. 68
Figura 67. Simulación del panel fotovoltaico y el convertidor boost.	70
Figura 68. Predicción de nubosidad 08/06/2020.....	70
Figura 69. Comparación de IH.....	70
Figura 70. Corriente de salida 08/06/2020.....	70
Figura 71. Predicción de nubosidad 06/06/2020.....	70
Figura 72. Comparación de IH.....	70
Figura 73. Corriente de salida 08/06/2020.....	70

Nomenclatura

Irradiación solar y nubosidad.

I_d	Irradiación directa solar sobre una superficie horizontal.
I_b	Irradiación difusa solar sobre una superficie horizontal.
M_t	Índice de claridad.
$I_{b\beta}$	Irradiación directa solar sobre una superficie inclinada.
$I_{d\beta}$	Irradiación difusa solar sobre una superficie inclinada.
I_r	Irradiación solar reflejada.
F	Brillo de horizonte.
a_n	Ángulo circunsolar.
θ	Ángulo de incidencia.
θ_z	Ángulo cenital.
δ	Ángulo de declinación.
\mathbb{I}	Ángulo del día.
ω	Ángulo hora.
LT	Tiempo estándar local.
LS	Meridiano estándar para una zona local.
LL	Longitud de la ubicación.
ET	Ecuación de tiempo.
Y	Acimut solar.
α	Latitud.
I_0	Radiación extraterrestre.
EO	Factor de corrección de excentricidad.
ω_s	Ángulo al amanecer.
I_{bN}	Irradiación de haz solar.
\widehat{I}_H	Irradiación solar global sobre una superficie horizontal teórica.
I_H	Irradiación solar global sobre una superficie horizontal corregida.
h	Día.
d	Mes.
m	Valor de pixel.
V_{PX}	Muestra de nubosidad.
v_k	

Panel fotovoltaico y
convertidor boost

\widehat{I}_H	Predicción de irradiación solar sobre una superficie horizontal.
PV	Fotovoltaico.
CD	Corriente directa.
I_L	Corriente foto generada.
I	Corriente de salida.
V	Voltaje de salida de la celda solar.
I_{os}	Corriente de saturación inversa del diodo.
K	Constantes Boltzmann's.
R_s	Resistencia en serie de la celda solar.
R_{sh}	Resistencia shunt de la celda solar.
n	Factor de desviación del diodo.
T	Temperatura de la celda.
MPPT	Punto de máxima potencia
D	Diodo.
C	Capacitor.
v	Voltaje.
R	Resistencia.
i	Corriente.
L	Inductancia.

Red neuronal artificial.

ANN	Red neuronal artificial.
x_h	Datos de entrada.
w_h	Peso sináptico.
b	Bias.
i	Neurona de la primera capa oculta.
f	Función de activación.
j	Capa oculta.
y	Salida de la red.

Capítulo 1

Introducción

Hoy en día la energía eléctrica se ha convertido en un recurso prácticamente indispensable para el ser humano. Actualmente, existen diversas opciones para generar electricidad, de forma no renovable: carbón, petróleo, nuclear entre otras. Asimismo, también existen alternativas renovables, tales como la eólica, hidráulica y fotovoltaica (Viloria, 2008). El beneficio que aportan las energías renovables, son diversos y su desempeño varía según las condiciones en las que se encuentren.

Una de las fuentes de energía renovable que ha ganado gran popularidad en estos últimos años ha sido la generación de energía a partir de sistemas fotovoltaicos. Un ejemplo, es México, que según el Reporte de Avance de Energías Limpias del Primer Semestre 2018, ha tenido un importante crecimiento de generación de energía a partir de sistemas fotovoltaicos del 2017 al 2018, lo que representa un aumento del 340.50% (SENER, 2018).

Por lo antes mencionado, es necesario seguir analizando este tipo de fuentes de energía, con el fin de mejorar su adaptación a la vida cotidiana de las personas y a su vez, obtener el máximo aprovechamiento.

De todas las fuentes renovables la generación de energía fotovoltaica se considera que es, una de las más disponibles y fáciles de aprovechar. Sin embargo, su dependencia climatológica la convierte en una fuente con constantes variaciones en su producción de energía, por lo que se han buscado diversas formas para realizar una predicción de la capacidad de generación fotovoltaica como, métodos de convolución (R. N. Senapati, 2016), modelos determinísticos (F. Serttas, 2018), con redes neuronales (K. Guo, 2020), entre otros, buscando predecir en sus respectivos enfoques las diferentes variables involucradas en este proceso, uno de los factores que más influye en la generación de energía fotovoltaica es la aparición de cúmulos de nubes, los cuales disminuyen considerablemente la producción de energía y al ser una condición sumamente variable provoca intermitencia en la generación de electricidad.

Esta tesis presenta un esquema para obtener una predicción de la irradiación solar (G) en una zona determinada, utilizando modelos matemáticos y realizando correcciones con redes neuronales (ANN), esto con el fin de visualizar una referencia con respecto al nivel de irradiancia, siendo este uno de los factores primarios para evaluar el nivel de energía producido por sistemas fotovoltaicos (PV).

Una vez obtenidos los niveles de nubosidad (VP_x) en los instantes de tiempo próximos, se introducen a las predicciones teóricas de irradiación (\hat{I}_H) con las cuales se obtienen los niveles de irradiación pronosticados teóricamente por los modelos matemáticos, pero influenciados por los niveles de nubosidad, para posteriormente ser evaluados por los modelos matemáticos de un panel fotovoltaico y convertidor boost y obtener un barrido de los niveles de potencia y voltaje producidos.

En la Figura 1, se muestra una representación general de cómo sería aplicado este tipo de estrategia, tomando en cuenta que las predicciones de nubosidad ya realizadas (y posteriormente corregidas) para después ser analizadas con modelos matemáticos de panel fotovoltaico y el convertidor boost.

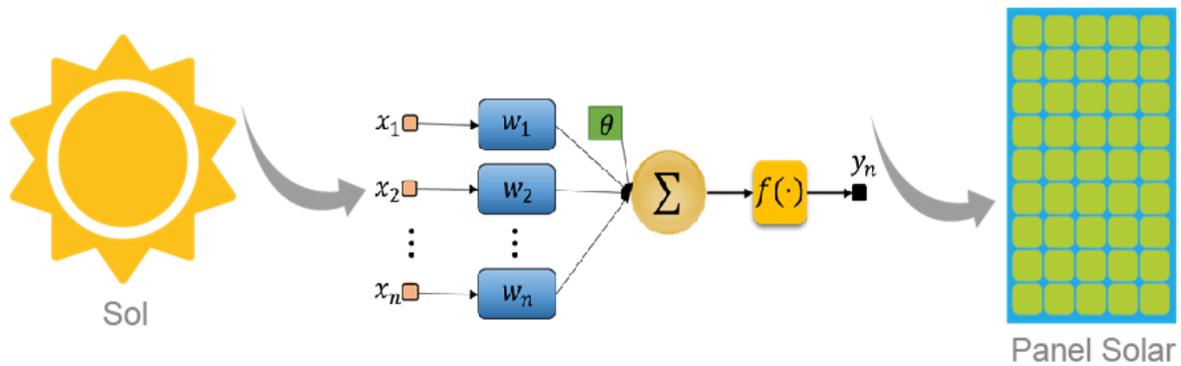


Figura 1. Diagrama general de aplicación

1.1. Problemática de investigación

La generación de energía renovable y su conexión a la red eléctrica hoy en día representan un importante estudio, un ejemplo de ello son los sistemas fotovoltaicos los cuales representan una alternativa viable en la generación de energía eléctrica debido a las grandes ventajas que tienen sobre otras fuentes de energía renovable.

Este tipo de generación de energía será una de las más importantes para el futuro en energías limpias (A. E. Mejía C. A., 2010); sin embargo, éstas a su vez representan inconvenientes, los cuales dificultan su conexión a la red eléctrica al conectarse a los sistemas convencionales de energía, y pueden provocar alteraciones en la estabilidad del sistema, a su vez, su naturaleza variable, intermitente e impredecible ocasiona que no se garantice la generación constante de energía con la cual se consideran que no son fiables (A. E. Mejía M. H., 2011).

Uno de los problemas involucrados con la generación de energía a partir de sistemas fotovoltaicos, es la baja predictibilidad en la producción de energía, siendo la presencia de cúmulos de nubosidad presentes en la zona, uno de los factores que interviene directamente

en este proceso, los cuales representan un elemento sumamente variable y de gran influencia sobre los sistemas fotovoltaicos.

La problemática que se abordará en esta tesis será desarrollar un algoritmo que involucre datos de nubosidad en la predicción de generación fotovoltaica, elevando el nivel de confiabilidad de la energía producida y combinando estos datos con modelos matemáticos de un sistema fotovoltaico y de un convertidor boost esto no con el fin de erradicar la problemática, sino de prevenir al usuario y a todos los involucrados para hacer un uso completo de esta.

En la Figura 2 se muestra una representación gráfica de cómo los niveles de nubosidad afectan a los sistemas fotovoltaicos, esto porque no solo pueden crear diversos tipos de sombra según la clasificación de la nube, sino también, que pueden influir de forma total o parcial a estos tipos de sistemas.

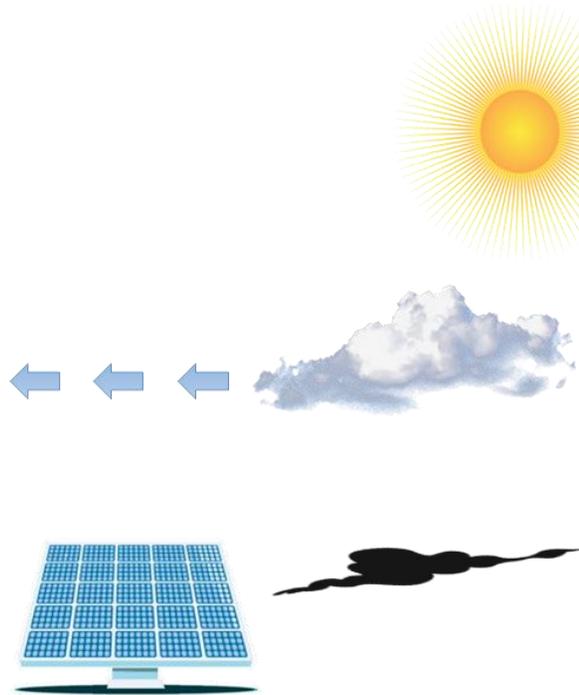


Figura 2. Aparición de cúmulos de nubosidad

1.2. Estado del arte

En (B. Chen, 2020) se analizan los efectos meteorológicos sobre la generación de energía fotovoltaica, así como el grado de impacto en diferentes períodos de tiempo. De acuerdo con las características de las coordenadas de radiación, propone un método de clasificación de radiación (RCC) para clasificar y seleccionar periodos de tiempo similares, datos en los cuales se incluye la salida de potencia y factores meteorológicos mismos que representan el

conjunto de datos de entrenamiento para una red neuronal, para esto se hace uso de una red neuronal recurrente de memoria a largo y corto plazo (LSTM).

En (Selvakumar, 2017) se enfoca en comparar las predicciones obtenidas por tres tipos de estructuras para redes neuronales artificiales (ANN), 1 red neuronal perceptron multicapa (MLPN), 2 red neuronal de base radial (RBF), 3 Red neuronal recurrente y métodos de regresión clásicos, concluyendo que los modelos de redes neuronales artificiales aportan mejores resultados de predicción.

En (S. M. Lurwan, 2014) se presenta un modelo de simulación MATLAB / SIMULINK para predecir la radiación solar horaria utilizando el modelo de radiación modificado de Hottel. Este modelo permite predecir la radiación solar por horas utilizando los valores actuales del tipo de día y la geografía de la ubicación. Mientras predice la producción de energía, el modelo requiere información del pronóstico del tiempo del día para predecir, algunos datos de la hoja de datos del módulo solar son el uso y la radiación predicha.

En (C. Wan, 2015) proporciona una revisión de las metodologías de predicción teóricas tanto para los recursos solares como para la energía fotovoltaica. Las aplicaciones de la previsión solar en la gestión energética de redes inteligentes también se investigan, concluyen que los modelos de predicción de energía fotovoltaica y de potencia solar se dividen en cuatro clases: modelos estadísticos, modelos basados en AI, modelos físicos y modelos híbridos.

En (A. K. Yadav, 2015) se utilizan para la predicción de la radiación solar global diaria (DGSR) con redes neuronales (ANN). La predicción se realiza con tres combinaciones de variables de entrada a saber 1 Temperatura promedio del aire, temperatura máxima del aire y temperatura mínima del aire, 2.- Temperatura promedio del aire y temperatura máxima del aire, 3 Temperatura promedio del aire.

Puede usarse para predecir DGSR para sitios donde la radiación solar medida no está disponible, el método útil para dimensionar sistemas solares fotovoltaicos.

En (C. Huang, 2016) presenta un método para mejorar la precisión de una red neuronal artificial (ANN). La estimación es basada en la producción de energía fotovoltaica, mediante dos entradas, el ángulo cenital solar y el ángulo azimutal solar, además de la información medioambiental. Ángulo cenital solar y ángulo azimutal solar define la posición solar en el cielo; por lo tanto, se reduce o elimina la pérdida de precisión del modelado debido a los impactos del ángulo de incidencia solar y el espectro solar. El modelo algebraico y el modelo de regresión polinomial que usan información ambiental solo de la irradiancia horizontal y la temperatura del módulo.

En (M. Pierro, 2016) se compara modelos basados en datos utilizando diferentes datos de entrada de predicción numérica. Desarrollan algoritmos estadísticos, estocásticos e híbridos de aprendizaje automático y se utilizan como entrada los datos. Este método depende de la capacidad del modelo de aprendizaje automático para corregir el error de sesgo de los datos de entrada.

En (G. Graditi, 2016) se comparan un modelo fenomenológico y dos modelos de aprendizaje estadístico, una red neuronal de perceptrón multicapa (MLP) y un enfoque de regresión. La aplicación del modelo fenomenológico requiere la disponibilidad de parámetros de diseño y dispositivos técnicos específicos.

En (C. Yassine, 2019) se analiza el comportamiento, eficiencia y trayectoria de los modelos de celdas solares, compara su eficiencia y describe la diferencia entre los modelos de celda solar, presenta 3 diferentes tipos de modelos, modelo simplificado de diodo único (SSDM), modelo detallado de diodo único (SDM) y modelo de doble diodo (DDM), expone sus virtudes y deficiencias, menciona en las condiciones óptimas en las que se debe plantear el uso de alguno de los modelos y expone un nuevo método de aplicación.

En (N. Aoun, 2019) se presenta y analiza el rendimiento de un módulo fotovoltaico monocristalino. Compara los resultados reales con los calculados por cuatro métodos diferentes: modelo de diodo único (cuatro y cinco parámetros) y de diodo doble (siete parámetros). Comparan el índice de rendimiento promedio mensual, la eficiencia y la energía de salida anual.

En (F. Zhu, 2019) se propone un método para predecir la energía fotovoltaica basado en la agrupación de datos y la optimización de parámetros. El método propuesto se expone de la siguiente manera: primero, la característica meteorológica a recopilar se determina analizando el modelo físico de la celda fotovoltaica y la información meteorológica numérica recopilada se divide en un conjunto de categorías. Posteriormente, utilizan una red neuronal de BP se adopta y se entrena para categorías individuales, y se propone un método de optimización de parámetros adaptativos

En (Z. Si, 2020) se propone un método híbrido para predecir la irradiancia horizontal global (GHI) en horizontes temporales de 1, 2, 3 y 4 horas, combinando las imágenes satelitales e información meteorológica. Las imágenes satelitales se preprocesan para eliminar los efectos causados por el ángulo cenital solar. Los factores de cobertura de nubes se extraen de imágenes satelitales mediante el uso de una red neuronal convolucional modificada (CNN). Después de eso, se desarrolla el modelo de pronóstico GHI que se basa en el uso combinado de información meteorológica y factores de cobertura de nubes.

En (E. I. Batzelis, 2018) se presentan una representación en espacio de estados de la dinámica del sistema fotovoltaico impulsada por la variación de la irradiancia. Expone un modelo dinámico fotovoltaico en forma completamente de espacio de estado que incorpora la función de seguimiento del punto de máxima potencia. Con este fin, la “Lambert W function” se utiliza para expresar las ecuaciones del generador fotovoltaico de forma explícita.

En (F. Serttas, 2018) se presentan una metodología llamada Mycielski-Markov para pronosticar la generación de energía solar a corto plazo. Este método híbrido se desarrolla con base a dos técnicas diferentes; Método de procesamiento de señales de Mycielski y cadena probabilística de Markov. En método de Mycielski investiga el historial de datos y encuentra la recurrencia de los datos de radiación solar. Predicen los siguientes los datos debido a la recurrencia de forma determinista. Markov produce las probabilidades de

transición de los estados de energía solar y pronostica un nuevo estado de acuerdo con estas probabilidades.

Tabla 1. Resumen de estado del arte.

Referencia	Aplicación	Estrategia
(B. Chen, 2020)	Sistemas fotovoltaicos	Analiza el grado de impacto en diferentes períodos de tiempo sobre los sistemas fotovoltaicos. De acuerdo con las características de las coordenadas de radiación.
(Selvakumar, 2017)	Red neuronal artificial	Propone un modelo que es aplicable junto con datos de radiación solar utilizando redes neuronales artificiales.
(S. M. Lurwan, 2014)	Irradiación solar	Se basa en el modelo de irradiación de Hottel.
(C. Wan, 2015)	Sistemas fotovoltaicos	Analiza la metodología teórica de predicción aplicada a sistemas fotovoltaicos.
(A. K. Yadav, 2015)	Irradiación solar	Analiza la predicción de la radiación solar global diaria con redes neuronales. Enfocándose a la combinación de 3 variables: Temperatura promedio del aire, temperatura máxima del aire y temperatura mínima del aire.
(C. Huang, 2016)	Sistemas fotovoltaicos	Presenta un método para mejorar la precisión de una red neuronal artificial. La estimación es basada en la producción de energía fotovoltaica.
(M. Pierro, 2016)	Redes neuronales artificiales	Analiza modelos basados en datos utilizando diferentes entradas. Analiza el desarrollo de algoritmos estadísticos, estocásticos e híbridos de aprendizaje automático.
(G. Graditi, 2016)	Redes neuronales artificiales	comparan un modelo fenomenológico y dos modelos de aprendizaje estadístico, una red neuronal de perceptrón multicapa.
(C. Yassine, 2019)	Sistemas fotovoltaicos	Expone la aplicación de 3 modelos de celda solar: modelo simplificado de diodo único (SSDM), modelo detallado de diodo único (SDM) y modelo de doble diodo (DDM)
Seasonal Performance Comparison of Four (N. Aoun, 2019)	Sistemas fotovoltaicos	Compara la eficiencia entre el modelo simplificado de diodo único, modelo

		detallado de diodo único y modelo de doble diodo.
(F. Zhu, 2019)	Sistemas fotovoltaicos	Realiza predicciones a partir de datos meteorológicos y una red neuronal de tipo back-propagation.
(Z. Si, 2020)	Sistemas fotovoltaicos	Realiza predicciones de la irradiación solar sobre una superficie horizontal, en horizontes de tiempo de 1, 2, 3 y 4 horas a partir de imágenes satelitales y una red neuronal convolucional modificada.
(E. I. Batzelis, 2018)	Sistemas fotovoltaicos	Presenta un modelo de panel fotovoltaico dinámico en el cual el dato de entrada es la irradiación solar. Este método está expresado en espacio de estados y utiliza la función de Lambert W en Matlab para expresar las ecuaciones de forma explícita.
(F. Serttas, 2018)	Sistemas fotovoltaicos	Utiliza una metodología llamada Mycielski-Markov para pronosticar la generación de energía solar a corto plazo

1.3. Planteamiento del problema

Para realizar una predicción de la capacidad de generación de energía fotovoltaica es necesario comprender primero que el factor con mayor influencia en la entrada de este tipo de sistemas son los niveles de irradiación que captada en ciertos lapsos de tiempo, usualmente a lo largo del día, es por ello que la variable a predecir son los niveles de irradiación, sin embargo, éstos se ven afectados por la fecha y el estado climático en el que se encuentre el análisis, en la literatura ya se encuentran estudiados los niveles de nubosidad con respecto de estos factores, por lo que la problemática a solucionar de esta tesis se enfocará a los cúmulos de nubosidad presentes en una zona determinada, buscando con base en un conjunto de muestras predecir los niveles de nubosidad en las horas siguientes.

1.4. Propuesta de solución

Con los trabajos mencionados en el estado del arte se puede analizar una tendencia de estudio la cual permite delimitar el tema de investigación, el cual se propone una opción para realizar estimaciones de la capacidad de generación de energía fotovoltaica haciendo uso de ANN y modelos matemáticos.

De tal forma, como propuesta de solución se plantea realizar predicciones de capacidad de generación de energía fotovoltaica integrando niveles de nubosidad que influyen en la zona y a partir de redes neuronales artificiales realizando tanto predicción de nubosidad como la integración de esta con modelos matemáticos de irradiación solar, datos con los cuales,

posteriormente, son analizados en un modelo matemático de panel solar y después en un modelo de convertidor boost para visualizar el proceso de predicción, siendo más claro, esta propuesta de solución se puede separar en tres etapas, en la primera se obtiene el índice de nubosidad (V_{PX}) en la cual se utiliza la primera red neuronal artificial (ANN_1) y con base en modelos matemáticos la irradiación solar global (\hat{I}_H), para la segunda etapa se utilizan los datos obtenidos en la etapa anterior (\hat{I}_H y V_{PX}) para realizar una corrección en la predicción teórica introduciendo en esta los niveles de nubosidad obteniendo la irradiación solar global real sobre una superficie inclinada (G) y finalmente la tercera etapa, la simulación de esta predicción utilizando modelos matemáticos de un panel solar y un convertidor tipo boost obteniendo la potencia de salida suministrada en los lapsos de tiempo analizados.

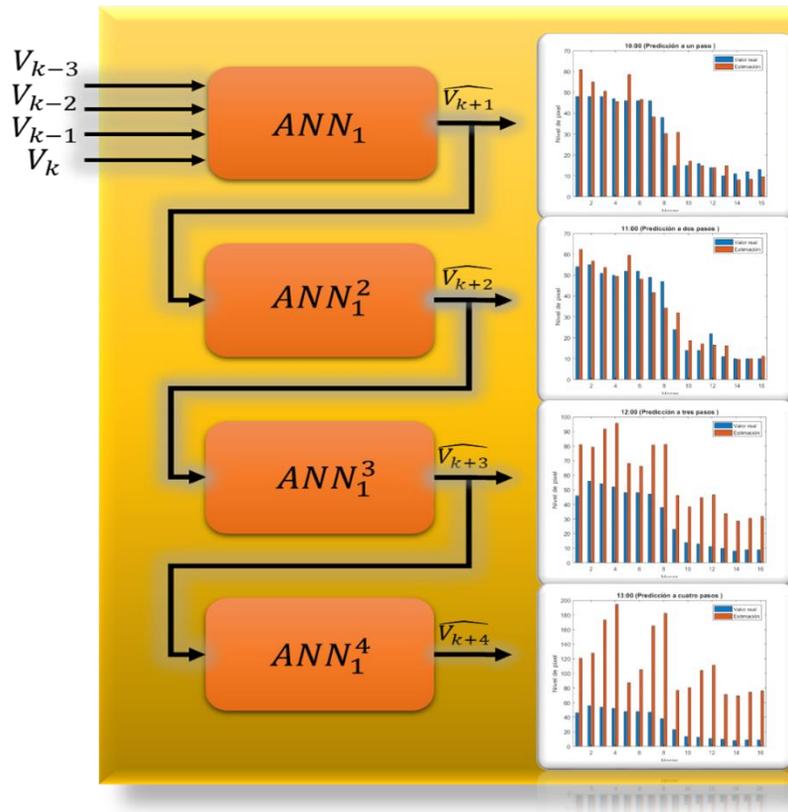


Figura 3. Esquema de predicción.

Introduciendo una explicación visual de la etapa 1 de esta propuesta, en la Figura 3 se representa gráficamente la estructura de la ANN_1 en la cual se puede observar la comparación en los índices de nubosidad obtenidos (V_{PX}) y los índices reales, matemáticamente representados en las ecuaciones (1) y (2). En la figura se pueden identificar algunos de los resultados obtenidos con ANN_1 permitiendo realizar una comparación visual de estos datos.

$$V_{PX} = [v_{k-3}; v_{k-2}; v_{k-1}; v_k] \quad (1)$$

$$v_i \in \mathbb{R}^{16} \quad (2)$$

En la Figura 4 se presenta el esquema general en el que se basó esta tesis. Éste inicia con la extracción de imágenes satelitales obtenidas de Global Satellite Mapping of Precipitation (GSMaP) (T. Ushio, 2020), localizando y señalizando un cuadrante de análisis, además de proporcionar la fecha y hora en cuestión, posteriormente se aplica un tratamiento de imágenes en escala de grises para después extraer (V_{PX}), valor que utiliza como entrada ANN1 para realizar la predicción de V_{PX} en las horas siguientes y obteniendo V_{PX} pronosticado, posteriormente, es necesario obtener la irradiación solar global horizontal calculada (\hat{I}_H) obtenida del modelo matemático al cual se le proporciona los datos de hora (h), día (d) y mes (m). Una vez obtenido V_{PX} y \hat{I}_H se introducen a la red neuronal artificial 2 (ANN2) junto con h para realizar una corrección a I_H ya introduciendo V_{PX} que indicaría el nivel de nubosidad influyendo sobre \hat{I}_H y obteniendo finalmente la irradiación solar global horizontal real (I_H), valor que regresa al modelo teórico el cual depende de \hat{I}_H para obtener la irradiación solar global sobre una superficie inclinada (G) este último cálculo agregando la inclinación que tienen los sistemas fotovoltaicos y con esto precisar mejor el cálculo de producción de energía.

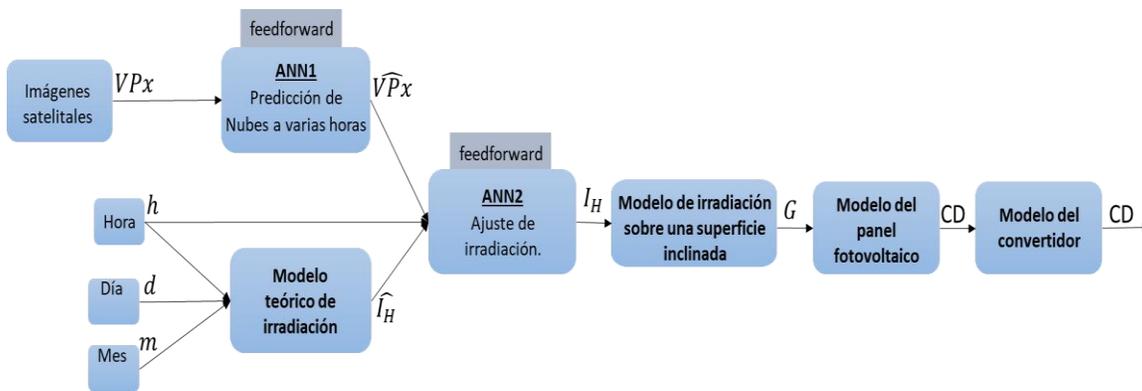


Figura 4. Esquema general.

1.5. Objetivos

1.5.1. Objetivo general

- Desarrollar una estrategia de estimación y predicción de la capacidad de generación de energía eléctrica de un sistema fotovoltaico, que tome en cuenta las condiciones climáticas presentes a lo largo de un día.

1.5.2. Objetivos específicos

- Desarrollar un modelo matemático de irradiación solar que incluya aspectos de clima, datos históricos y localización de los paneles geográficamente.

- Diseñar un sistema de generación fotovoltaica a partir de la información de irradiación solar.
- Diseñar un sistema de información local que permita la predicción de nubosidad.

1.6. Metas

- Realizar predicciones de los niveles de nubosidad en una zona determinada.
- Integrar datos reales con modelos matemáticos para el análisis del comportamiento de sistemas fotovoltaicos en presencia de nubosidad.
- Integrar un modelo de predicción de irradiación que involucre niveles de nubosidad presentes en la zona, aplicado modelos matemáticos de un panel fotovoltaico y un convertidor tipo boost

1.7. Justificación

En la generación de energía eléctrica a partir de sistemas fotovoltaicos tiene como ventaja aprovechar uno de los recursos naturales más abundante la irradiación solar, sin embargo, el proceso por cual se expone este recurso es muy complejo y variado, lo que provoca dificultades para aprovechar esta fuente de energía.

El nivel de nubosidad presente en la zona es uno de los factores con más influencia en el proceso. La presencia de nubosidad impacta grandes fluctuaciones en la generación de energía, además los cúmulos nubosos son amorfos, lo cual provocan sombras que en pueden cubrir de forma parcial un panel fotovoltaico, su movimiento depende de las corrientes de aire, provocando grandes cambios en su curso de movimiento, tienden a dispersarse después de un determinado tiempo, lo cual su presencia no afectará según la trayectoria que tengan y el nivel de sombra depende de la altura y concentración que tenga, provocando diversos cambio en el efecto fotovoltaico.

En la literatura se mencionan diversos estudios los cuales han buscado disminuir esta problemática, por ello, podemos encontrar grandes avances en el tema, sin embargo, este tipo de estudios nos lleva a buscar cual es la opción con mejor solución y a comparar cada una de las posibles combinaciones mejorar la solución.

Como se ha mencionado antes, existen diversas formas de predecir el estado los niveles de generación de energía eléctrica a partir de sistemas fotovoltaicos, como lo son, modelos matemáticos, redes neuronales, modelos determinísticos e incluso métodos probabilísticos.

Esta tesis se enfocará a abordar predicciones de la capacidad de generación de energía producida por sistemas fotovoltaicos, con la particularidad de combinar modelos matemáticos con redes neuronales e integrando con esta mayor precisión en las predicciones y con esto elevando el nivel de confiabilidad en estos tipos de sistemas.

1.8. Organización del documento

La organización de este documento busca familiarizar al lector con temas como teoría de las diferentes partes del proceso de predicción, diseño de redes neuronales, efectos influyentes en el proceso y modelos aplicados en el método de predicción.

En este capítulo se presentó la motivación por la cual se realizó este tema de investigación, posteriormente mencionado los objetivos planteados y metas a cumplir, también se da un análisis de las investigaciones más recientes relacionadas al tema central de esta tesis. En los capítulos próximos se expondrá de forma detallada la temática involucrada en el desarrollo de esta tesis.

El *Capítulo 2* se habla de manera específica sobre los modelos de irradiación solar, desglosando las ecuaciones necesarias para realizar el cálculo de la irradiación solar global sobre una superficie inclinada, así como se mencionan las variables que involucran este cálculo.

- Ecuaciones para calcular la irradiación directa sobre una superficie horizontal e inclinada.
- Ecuaciones para calcular la irradiación difusa sobre una superficie horizontal e inclinada.
- Cálculos de las condiciones planetarias.
- Modelo matemático de irradiación solar global sobre una superficie horizontal e inclinada

En el *Capítulo 3* se habla exclusivamente de los modelos matemáticos de un panel solar y de un convertidor boost, también se definen conceptos y definiciones útiles para la comprensión del funcionamiento, se menciona el algoritmo utilizado para mantener el máximo punto de potencia y se muestran algunas gráficas de funcionamiento.

En el *Capítulo 4* se habla de la nubosidad, se definen algunos conceptos sobre esta y se muestran imágenes satelitales para mejorar la interpretación y analizar el comportamiento de los cúmulos de nubosidad. Otro punto que se aborda en este capítulo son los conceptos y definiciones de redes neuronales enfocándonos en el tipo de red neuronal que se está utilizando en esta tesis, también se menciona como se hace uso de este tipo de redes en esta tesis.

En el *Capítulo 5* se exponen las conclusiones a las cuales se llegan en esta tesis con respecto al desarrollo realizado, también se mencionan las aportaciones que se obtuvieron y finalmente se plantean algunos de los trabajos que posiblemente se puedan abordar en el futuro con respecto a este trabajo de tesis.

Capítulo 2

Modelos de irradiación teórica

El objetivo de este capítulo es explicar de manera detallada el modelo de irradiación solar global sobre una superficie inclinada. existen diversos tipos de modelos utilizados para obtener dicha irradiación, para esta tesis fue tomado el modelo de Pérez (Seyed Abbas Mousavi Maleki, 2017). El modelo de irradiación solar se divide en dos partes, la primera parte se presenta el modelo de irradiación solar sobre una superficie horizontal y para la segunda el modelo de irradiación sobre una superficie inclinada, esto es necesario puesto que al tomar la irradiación solar sobre una superficie inclinada aporta datos más reales a la cantidad de irradiación que percibe un sistema fotovoltaico. Para realizar el cálculo de irradiación solar es necesario obtener datos angulares, como de la zona de análisis, los cuales se explican a continuación.

2.1. Irradiación solar

En las estaciones meteorológicas, la radiación solar global generalmente se mide en superficies horizontales. No obstante, para aprovechar al máximo la radiación solar en las superficies de los colectores, los sistemas solares estacionarios convencionales, tanto fotovoltaicos como colectores solares, se montan sobre superficies inclinadas. La radiación solar global en superficies inclinadas se puede estimar a partir de la radiación solar global en superficies horizontales utilizando varios modelos. Los modelos se pueden utilizar para estimar los componentes de la irradiación solar global horaria en superficies horizontales (para irradiación directa y difusa) y superficies inclinadas (para irradiación directa, difusa y reflejada en el suelo) (S. A. M. Maleki H. H., 2017).

2.1.1. irradiación solar global hora a hora en superficies horizontales (I_H)

La radiación solar global en superficies horizontales se puede medir con un piranómetro, que es un instrumento que mide la radiación solar global desde todas las direcciones. La radiación solar global en superficies horizontales se puede clasificar de la siguiente manera y representa la suma de estas:

$$I_H = I_d + I_b \quad (3)$$

- Irradiación solar difusa (I_b).

- Irradiación solar de haz directo (I_d) Solar.

2.1.2. Radiación difusa por hora en superficie horizontal (I_d)

La radiación solar difusa es una parte de la luz solar que atraviesa la atmósfera y es consumida, dispersada o reflejada por el vapor de agua, las partículas de polvo o la contaminación. Este tipo de radiación no puede arrojar sombras nítidas y, por lo tanto, no se puede enfocar. Un gran número de estaciones meteorológicas / radiométricas normalmente miden la irradiación global recibida en superficies horizontales. Recopilar tales mediciones presenta cierto grado de dificultad, principalmente debido al alto precio del equipo de medición. Por esta razón, se han definido varios modelos matemáticos para estimar la radiación difusa en superficies horizontales utilizando el índice de claridad (M_t). Con base en una parametrización a partir del índice de claridad es posible obtener I_d como se muestra a continuación.

$$\begin{cases} 0 < M_t \leq 0.24, & I_d = (1.0086 - 0.178M_t) \\ 0.24 < M_t \leq 0.8, & I_d = (0.9686 + 0.1325M_t + 1.4183Mt_2 - 10.1862Mt_3 + 8.3733Mt_4)I_{H1} \\ 0.8 < M_t \leq 1, & I_d = (1.0086 - 0.178M_t)I_{H1} \end{cases}$$

2.1.3. Radiación directa por hora en superficie horizontal (I_b)

Cuando la luz solar viaja a través de la atmósfera terrestre, parte de ella, llamada radiación de haz, incide en la superficie de la tierra, arrojando sombras nítidas y no se ve perturbada. La radiación normal directa sobre superficies horizontales (I_{bN}) se puede medir con un instrumento llamado pirheliómetro.

Como se mencionó anteriormente, la radiación solar global se calcula como la suma de la radiación difusa y la radiación directa sobre una superficie horizontal. Por lo tanto, la radiación directa (I_b) se puede calcular por la diferencia entre la radiación solar global (I_H) y la radiación difusa (I_d) en una superficie horizontal.

$$I_b = I_H - I_d \quad (4)$$

2.2.1. irradiación solar global hora a hora en superficies inclinadas (G)

La radiación del haz ($I_{b\beta}$), la radiación reflejada (I_r) y la radiación difusa ($I_{d\beta}$) son los tres componentes de la radiación solar global que incide sobre una superficie inclinada (G). La fracción de radiación incidente reflejada por el suelo se denomina radiación reflejada.

$$G = I_{b\beta} + I_{d\beta} + I_r \quad (5)$$

2.2.2. Radiación difusa por hora en superficie inclinada ($I_{d\beta}$)

Modelo de Pérez (S. A. Mousavi Maleki, 2017)

Capítulo 2. Modelos de irradiación teórica

La base del modelo de Pérez es un análisis matemático aplicado en profundidad de los componentes difusos del cielo. Este modelo divide la radiación difusa en tres componentes: fondo isótropo, circunsolar y zonas del horizonte. La ecuación gobernante es:

$$I_{d\beta} = I_d \left[1 + \frac{\cos\beta}{2} (1 - F_1) + \frac{F_1 a_1}{a_2} + F_2 \sin\beta \right] \quad (6)$$

En esta ecuación a_1 y a_2 representan ángulos sólidos ocupados por la región circunsolar, ponderados por su radiación de incidencia promedio sobre una superficie en ángulo y horizontal, respectivamente; F_2 y F_1 , son el brillo del horizonte adimensional y los coeficientes circunsolares, respectivamente. Los dos factores se definen de la siguiente manera:

$$a_1 = \max \{0, \cos\theta\} \quad (7)$$

$$a_2 = \max \{\cos 85^\circ, \cos\theta_z\} \quad (8)$$

Estos factores crecientes establecen los valores de la magnitud de la radiación dentro de las dos regiones anisotrópicas relevantes para las de la mayor parte del domo. Dentro del modelo, el grado de anisotropía podría ser un rendimiento de estas dos regiones únicamente. Por lo tanto, el modelo funcionará tanto como una configuración isotrópica ($F_1 = F_2 = 1$) como incorporando colectivamente un tiempo equivalente de aclarado del horizonte y/o circunsolar.

$$F_1 = \max \left\{ 0, \left[F_{11} + F_{12}\Delta + F_{13}\theta_z \left(\frac{\pi}{180} \right) \right] \right\} \quad (9)$$

$$F_2 = \left[F_{12} + F_{22}\Delta + F_{23}\theta_z \left(\frac{\pi}{180} \right) \right] \quad (11)$$

Los coeficientes $F_{i,j}$ requeridos se obtienen de (S. A. Mousavi Maleki, 2017) como se ve en la Tabla 2.

Tabla 2. Coeficientes $F_{i,j}$.

ϵ	F11	F12	F13	F21	F22	F23
1.000	-0.008	0.588	-0.062	-0.060	-0.072	-0.022
1065	0.130	0.683	-0.151	-0.019	0.066	-0.029
1.230	0.330	0.487	-0.221	0.055	-0.064	-0.026
1.500	0.568	0.187	-0.295	0.109	-0.152	0.014
1.950	0.873	-0.392	-0.362	0.226	-0.462	0.001
2.800	1.132	-1.237	-0.412	0.288	-0.823	0.056
4.500	1.060	-1.600	-0.359	0.264	-1.127	0.131
6.200	0.678	-0.327	-0.250	0.159	-1.377	0.251

2.2.3. Radiación directa sobre una superficie inclinada ($I_{d\beta}$)

El valor de la radiación del haz directo en una superficie en ángulo se puede calcular utilizando la siguiente ecuación:

$$I_{b\beta} = r_b I_b \quad (10)$$

Donde r_b es la relación entre la radiación por hora recibida por una superficie en ángulo y la de una superficie horizontal fuera de la atmósfera terrestre.

$$r_b = \cos\theta \cos\theta_z \quad (11)$$

Donde θ es el ángulo de incidencia de una superficie orientada al ecuador en grados, y θ_z es el ángulo cenital, que se define como el ángulo entre el sol y el polo del sistema de coordenadas horizontales, en grados. La figura 4 muestra un diagrama de la igualdad de ángulos θ y θ_z .

$$\begin{aligned} \cos\theta = & (\sin(\varphi) \cos(\beta) - \cos(\varphi) \sin(\beta) \cos(\gamma)) \sin(\delta) + (\cos(\varphi) \cos(\beta) \\ & + \sin(\beta) \cos(\gamma)) \cos(\delta) \cos(\omega) + \cos(\delta) \sin(\beta) \sin(\gamma) \sin(\omega) \end{aligned} \quad (12)$$

La relación matemática para el ángulo de incidencia θ viene dada por la siguiente ecuación para superficies alineadas en cualquier dirección con respecto al meridiano local.

2.2.4. Radiación reflejada en superficie inclinada (I_r)

La radiación reflejada de las primeras horas de la mañana y también de las últimas de la tarde suelen estar cerca de 1 o 0. Esto se debe principalmente a artefactos como el sombreado o el error instrumental del coseno. El albedo del suelo a menudo se estima en una constante de 0,2.

2.3.1. Desarrollo del modelo de irradiación solar sobre una superficie horizontal (I_H)

Para obtener I_H es necesario obtener los siguientes ángulos, con los cuales se determina el nivel de irradiación dependiendo del día en el que se encuentra.

Ángulo de declinación (δ):

La declinación es la distancia angular desde el norte o el sur de sol al ecuador de la Tierra, los valores angulares máximos y mínimos de declinación de la órbita terrestre producen las estaciones climáticas de la tierra. Estos ángulos ya se encuentran estudiados y por ello es posible obtener su valor a lo largo del año por medio de ecuaciones matemáticas, a continuación, se muestran las ecuaciones utilizadas para el cálculo, así como la simulación comparada con los datos esperados según (S. A. M. Maleki H. H., 2017).

$$\begin{aligned} \delta = & (0.006918 - 0.399912 \cos \Gamma + 0.070257 \sin \Gamma + 0.000907 \sin 2\Gamma \\ & - 0.002697 \cos 3\Gamma + 0.00148 \sin 3\Gamma) \left(\frac{180}{\pi} \right) \end{aligned} \quad (13)$$

Donde:

Γ es el ángulo de día y está representado por (29)

$$\Gamma = 2\pi \left(n - \frac{1}{365} \right) \quad (14)$$

n= es el número de día en el año por ejemplo 1 de enero de = 1, 20 de febrero = 51

Tabla 3. Declinación solar.

<i>n</i>	Fecha	(δ) esperada	(δ) Obtenida
81	21 de marzo	0	0.32
173	21 de junio	23.45	23.46
266	21 de septiembre	0	0.24
356	21 de diciembre	-23.45	-23.43

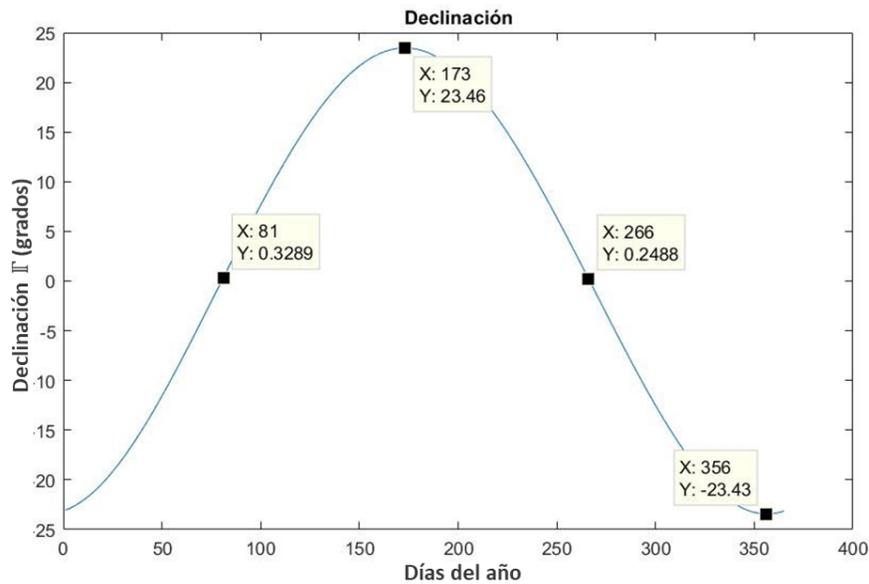


Figura 5. Simulación de declinación.

Ángulo Hora (ω)

El concepto de ángulo de hora se utiliza para describir la rotación de la tierra alrededor de su eje polar, dado que la Tierra gira 15° por hora, cada hora del mediodía solar corresponde a un movimiento angular del sol en el cielo de 15° , por la mañana el ángulo horario es positivo, por la tarde el ángulo horario es negativo. Es la distancia angular entre meridiano del observador y el meridiano cuyo plano contiene el sol. La siguiente ecuación puede utilizarse para calcular el ángulo horas en grados y ST es la hora local. En la figura 29 se muestra la simulación de ω tomando las 12 horas como el 0° puesto que es la división entre la mañana y la tarde y a partir de ahí el primer aumento de 15° a las 11:00 horas y el primer aumento negativo a las 13:00 horas (S. A. Mousavi Maleki, 2017).

$$\omega = 15(12 - ST); \quad ST = LT + \frac{ET}{60} + \frac{4}{60} [Ls - LL] \quad (15)$$

Donde:

LT: es el tiempo estándar local.

Ls: es el meridiano estándar para una zona local.

LL: es la longitud de la ubicación en estudio en grados.

ET: es la ecuación de tiempo dado por:

$$ET = 9.87\sin 2B - 7.53\cos B - 1.5\cos B; \quad B = \frac{360(n - 81)}{365} \quad (16)$$

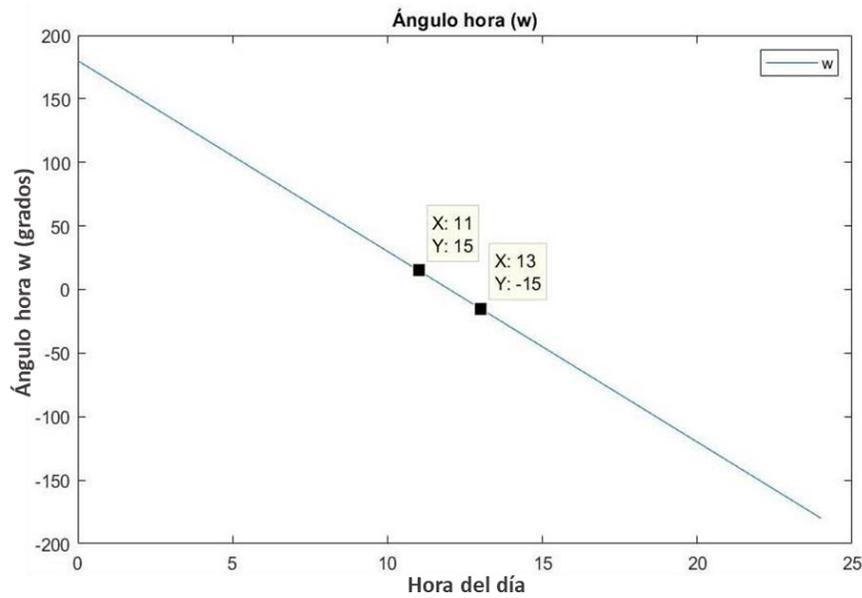


Figura 6. Simulación ángulo hora

Ángulo de acimut Solar (Y)

El desplazamiento angular desde el sur de la proyección de radiación del haz en el plano horizontal se define como el ángulo de acimut solar. En la figura 3 se simula el acimut solar comparado con datos obtenidos en la (S. A. Mousavi Maleki, 2017).

$$\gamma = \cos^{-1} \left(\frac{\sin \delta \cos \varphi - \cos \delta \sin \varphi \cos \omega}{\cos \alpha} \right) \quad (17)$$

$$\alpha = \sin^{-1}(\cos \theta_z) \quad (18)$$

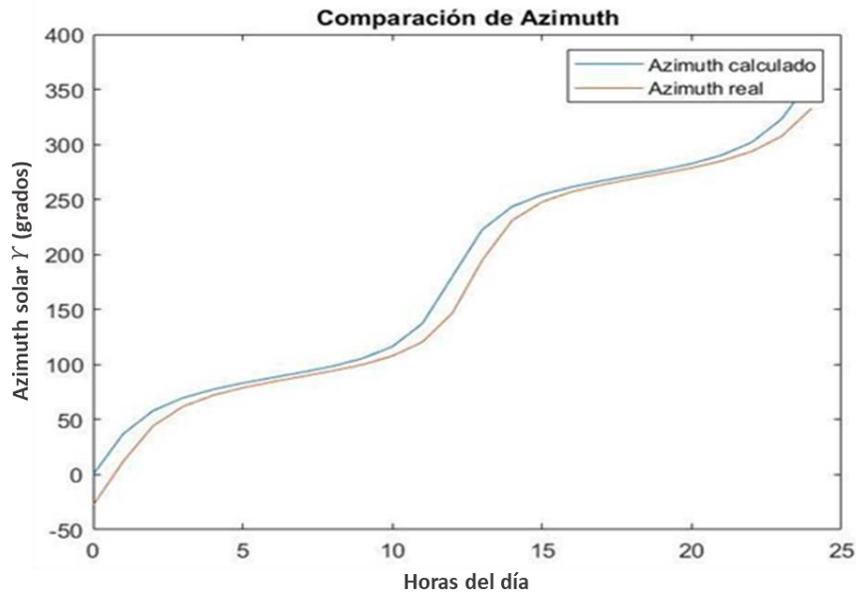


Figura 7. Simulación azimuth solar.

Ángulo de zenit solar (θ_z);

El ángulo de acimut es la dirección de la brújula que señala de donde proviene la luz del sol. Al mediodía solar, el sol siempre está directamente al sur en el hemisferio norte y directamente al norte en el hemisferio sur y el ángulo de acimut varía durante todo el día. En los equinoccios, el sol sale directamente desde el este y se pone directamente al oeste, independientemente de la latitud, con lo que el ángulo acimut es de 90° al amanecer y al atardecer 270° . Sin embargo, en general, el ángulo de acimut varía con la latitud y la época del año (luque, 2011)

$$\theta_z = \cos^{-1}(\sin(\delta)\sin(\varphi) + \cos(\delta)\cos(\varphi)\cos(\omega)) \quad (19)$$

Donde:

δ : declinación.

φ : Latitud.

ω : Ángulo hora.

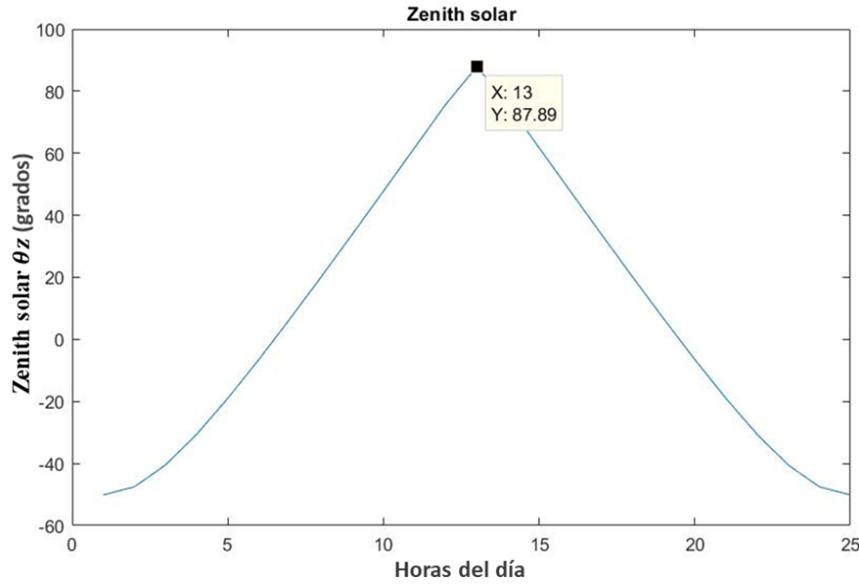


Figura 8. Simulación de zenit solar.

La latitud de un área es la posición pertinente al norte o al sur del ecuador. La variación de la latitud es de 0° a $\pm 90^\circ$ (positivo para el norte y negativo para el hemisferio sur) (S. A. Mousavi Maleki, 2017).

Hora radiación extraterrestre (I_0)

radiación extraterrestre se define como la incidencia de la radiación solar fuera de la atmósfera de la tierra y se calcula con la siguiente ecuación:

$$I_0 = \left((T\pi)Isc \cdot E_0 \left(-(\varphi 180)(w_s \sin(\varphi) \sin(\delta)) - (\cos(\varphi) \cos(\delta) \sin(w_s)) \right) \right) \quad (20)$$

Donde:

T es el tiempo siendo una constante de 24 horas, Isc es una constante solar (1367 W/m^2); E_0 es el factor de corrección de excentricidad; δ es el ángulo de declinación; φ es la latitud de la ubicación; ω_s ángulo al amanecer en grados. E_0 el factor de corrección de excentricidad se puede calcular de acuerdo con (S. A. Mousavi Maleki, 2017).

$$E_0 = 1 + 0.0033 \cos\left(\frac{360n}{365}\right) \quad (21)$$

Ángulo al amanecer (ω_s)

$$\omega_s = -\cos^{-1}(-\tan\delta \tan(\varphi)) \quad (22)$$

Irradiación difusa

Es la que se recibe del sol después de ser desviada por dispersión atmosférica. Es radiación difusa la que se recibe a través de las nubes, así como la que proviene del cielo. De no haber radiación difusa, el cielo se vería negro aun de día, como sucede con la Luna (Adalberto Tejeda Martínez, 2015).

Capítulo 2. Modelos de irradiación teórica

Para obtener la irradiación solar difusa en una superficie horizontal (I_d) se calcula la irradiación de haz solar (I_{bN}) extraída de valores constantes (A, B, C) que dependen de la fecha analizada y del ángulo de cenital (θ_z) calculado previamente (S. A. Mousavi Maleki, 2017).

Tabla 3. Valores constantes.

	Ener o	Febrer o	Marz o	Abri l	May o	Juni o	Juli o	Agost o	Septiembr e	Octubr e	Noviembr e	Diciembr e
A	1230	1215	1186	1136	1104	1088	1085	1107	1152	1193	1221	1234
B	0.142	0.144	0.156	0.180	0.196	0.205	0.207	0.201	0.177	0.160	0.149	0.142
C	0.058	0.060	0.071	0.097	0.121	0.134	0.136	0.122	0.092	0.073	0.063	0.057

$$I_{bN} = A \exp\left(-\frac{B}{\cos\theta_z}\right) \quad (23)$$

Donde:

I_{bN} : Irradiación de haz solar.

A, B, C : Valores constantes de la siguiente tabla:

Para calcular el índice de claridad (Mt), del cual depende de I_{d1} y de I_{H1} , obtenidos con modelos paramétricos (S. A. Mousavi Maleki, 2017).

$$I_{H1} = I_{bN} \cos \theta_z + I_{d1} \quad (24)$$

$$I_{d1} = C I_{bN} \quad (25)$$

Una vez obtenido índice de claridad (Mt) con la irradiación global horizontal (I_{H1}) y la irradiación extraterrestre se evalúa Mt con respecto de los siguientes parámetros, para finalmente obtener la irradiación difusa sobre una superficie inclinada (I_d).

$$Mt = \frac{I_{H1}}{I_0} \quad (26)$$

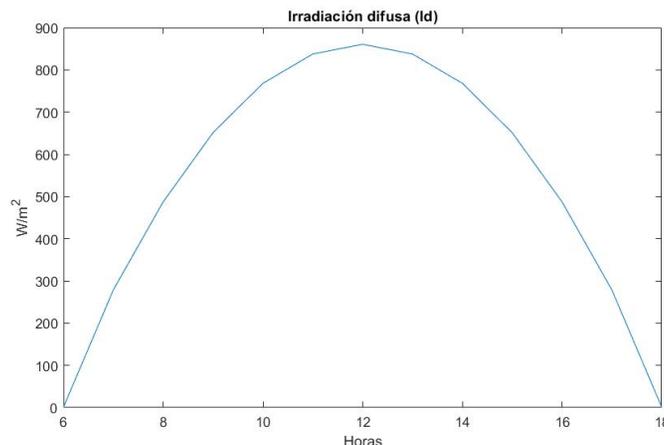


Figura 9. Simulación de irradiación difusa.

Irradiación solar directa

Es la parte que se recibe directamente del sol sin sufrir ninguna dispersión atmosférica.

$$I_b = I_H - I_d \tag{27}$$

$$I_b = I_{bN} \cos\theta_z \tag{28}$$

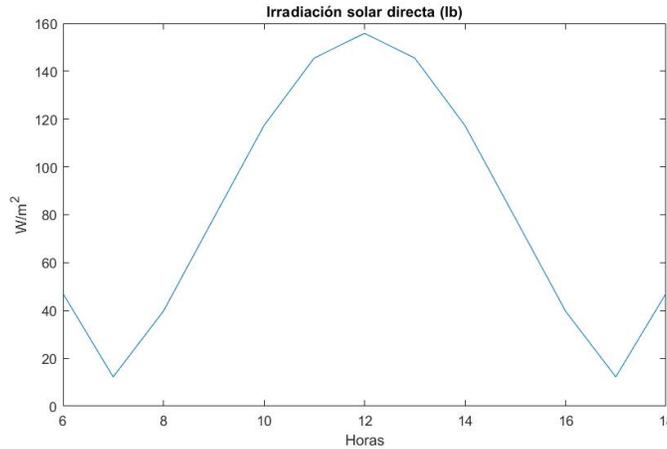


Figura 10. Simulación de irradiación directa

Radiación solar global sobre superficies horizontales (I_H)

la radiación solar global sobre superficies horizontales se puede medir con un piranómetro, que es un instrumento que mide la radiación solar global de todas las direcciones. La radiación solar global en superficies horizontales se puede clasificar como en irradiación solar directa (I_b) e irradiación solar difusa (I_d) (S. A. Mousavi Maleki, 2017).

$$I_H = I_d + I_b \tag{29}$$

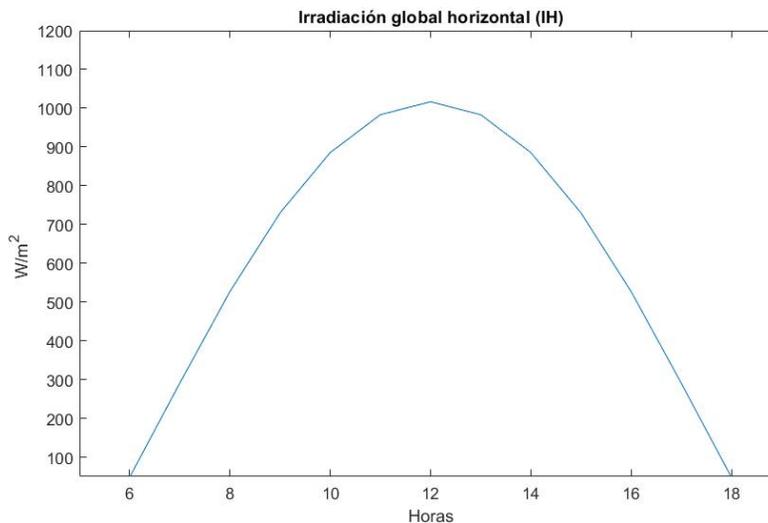


Figura 11. Simulación de irradiación global horizontal

2.4 Desarrollo del modelo de irradiación solar sobre una superficie inclinada (G)

La predicción de I_H , así como el efecto de la nubosidad sobre la irradiación se introduce en las ecuaciones de la irradiación inclinada realizando un despeje de I_H obteniendo los valores de I_d y también I_b de los cuales depende el cálculo de la irradiación inclinada.

$$I_H = I_d + I_b \quad (30)$$

$$I_H = I_{bN} \cos \theta_z + I_d \quad (31)$$

$$I_d = I_H - I_{bN} \cos \theta_z \quad (32)$$

$$I_b = I_H - I_d \quad (33)$$

En la literatura nos podemos encontrar con diversos modelos de irradiación solar difusa en una superficie inclinada, los cuales se desempeñan con mejor eficacia en diferentes tipos de condiciones climáticas, en esta tesis se utilizó el modelo de Pérez (S. A. Mousavi Maleki, 2017).

Modelo de Pérez:

$$I_d \beta = I_d \left[1 + \frac{\cos \beta}{2} (1 - F_1) + \frac{F_1 a_1}{a_2} + F_2 \sin \beta \right] \quad (34)$$

Donde:

I_d : Irradiación solar difusa sobre una superficie horizontal.

β : Inclinación del panel en grados.

F_1 y F_2 : Coeficientes de brillo de cielo.

a_1 y a_2 : Ángulos de la región circunsolar.

$$a_1 = \max \{0, \cos \theta\} \quad (35)$$

$$a_2 = \max \{\cos 85^\circ, \cos \theta_z\} \quad (36)$$

$$F_1 = \max \left\{ 0, \left[F_{11} + F_{12} \Delta + F_{13} \theta_z \left(\frac{\pi}{180} \right) \right] \right\} \quad (37)$$

$$F_2 = \left[F_{12} + F_{22} \Delta + F_{23} \theta_z \left(\frac{\pi}{180} \right) \right] \quad (38)$$

$$\Delta = m \frac{I_d}{I_0} \quad (39)$$

$$m = \frac{1}{\cos \theta_z} \quad (40)$$

Donde:

m : Masa del aire.

I_0 : Radiación extraterrestre $\left(\frac{W}{m^2}\right)$.

Es necesario calcular ε que está en función de la irradiación difusa para obtener $F_{i,j}$ propuesto en el modelo de Pérez (S. A. Mousavi Maleki, 2017):

$$\varepsilon = I_d + \frac{I_b}{I_d} + 5.535 \times \frac{10^{-6}\theta_z^3}{1+5.535 \times 10^{-6}\theta_z^3} \quad (41)$$

Tabla 4. Coeficientes para modelo de Pérez.

ε	F11	F12	F13	F21	F22	F23
1.000	-0.008	0.588	-0.062	-0.060	-0.072	-0.022
1.065	0.130	0.683	-0.151	-0.019	0.066	-0.029
1.230	0.330	0.487	-0.221	0.055	-0.064	-0.026
1.500	0.568	0.187	-0.295	0.109	-0.152	0.014
1.950	0.873	-0.392	-0.362	0.226	-0.462	0.001
2.800	1.132	-1.237	-0.412	0.288	-0.823	0.056
4.500	1.060	-1.600	-0.359	0.264	-1.127	0.131
6.200	0.678	-0.327	-0.250	0.159	-1.377	0.251

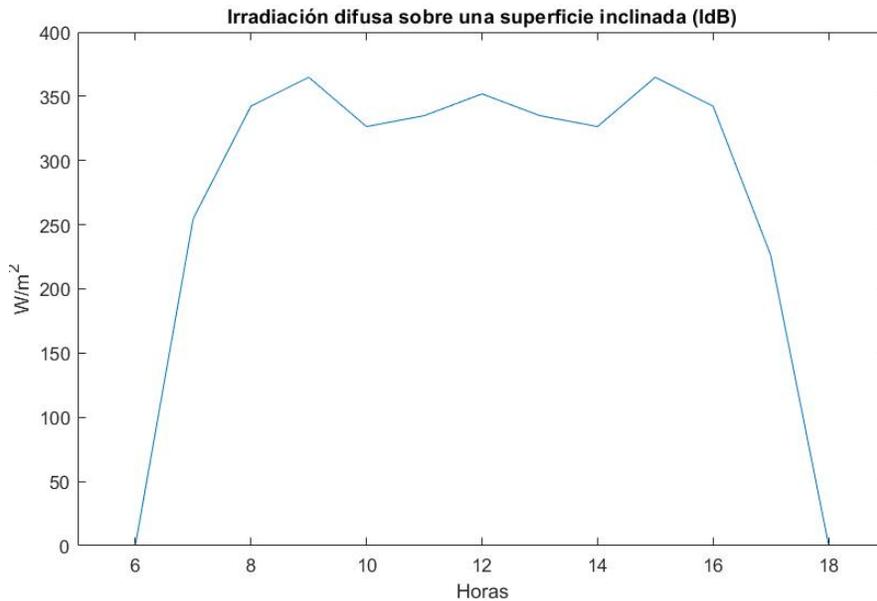


Figura 12. Simulación de Irradiación difusa sobre una superficie inclinada.

Irradiación solar directa sobre una superficie inclinada ($I_{b\beta}$)

Capítulo 2. Modelos de irradiación teórica

El valor de radiación de haz directo en una superficie en ángulo se puede calcular utilizando la siguiente ecuación (S. A. Mousavi Maleki, 2017):

$$I_{b\beta} = r_b I_b \quad (42)$$

Donde, r_b es la proporción de radiación por hora recibida por una superficie en ángulo con respecto a una superficie horizontal fuera de la atmósfera terrestre.

$$r_b = \cos\theta \cos\theta_z \quad (43)$$

θ_z : Ángulo de zenith solar.

θ : Ángulo de incidencia.

El ángulo de incidencia es obtenido por:

$$\cos\theta = (\sin\varphi\cos\beta - \cos\varphi\sin\beta\cos\gamma)\sin\delta + (\cos\varphi\cos\beta + \sin\beta\cos\gamma)\cos\delta\cos\omega + \cos\delta\sin\beta\sin\gamma\sin\omega \quad (44)$$

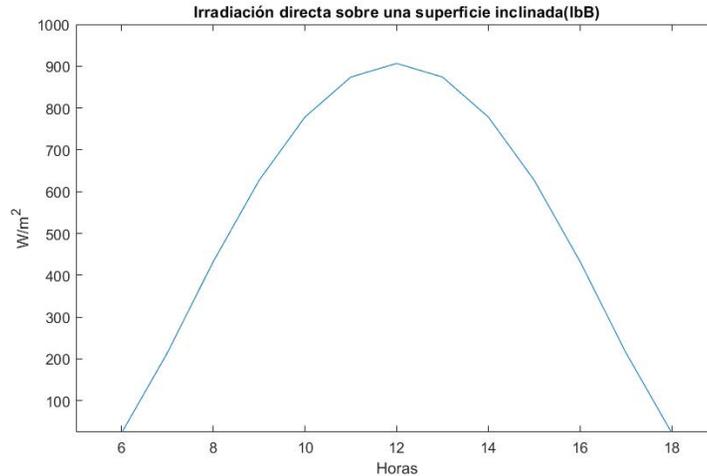


Figura 13. Simulación de irradiación directa sobre una superficie inclinada.

Estimación de la radiación reflejada sobre una superficie inclinada (I_r)

Parte de la radiación solar global que se refleja en la superficie terrestre y cualquier otro objeto interceptor se llama radiación reflejada. La irradiación reflejada a menudo se estima en un valor constante de 0.2 (S. A. Mousavi Maleki, 2017).

La irradiación global solar en una superficie inclinada (G) se calcula a partir de la irradiación directa en una superficie inclinada ($I_{d\beta}$), Irradiación difusa sobre una superficie inclinada ($I_{d\beta}$) y la Irradiación reflejada (I_r) (S. A. Mousavi Maleki, 2017), (S. Y. Alsadi, 2017).

$$G = I_{b\beta} + I_{d\beta} + I_r \quad (45)$$

Capítulo 2. Modelos de irradiación teórica

Tabla 5. Datos de Irradiación solar.

Fecha	Hora	Irradiación calculada H
1/6/2020	08:00	51.6
	09:00	291.6
	10:00	523.7
	11:00	722.6
	12:00	875
	13:00	970.8
	14:00	1003.4
	15:00	970.8
	16:00	875
	17:00	722.6
	18:00	523.7
	19:00	291.6
	20:00	51.6

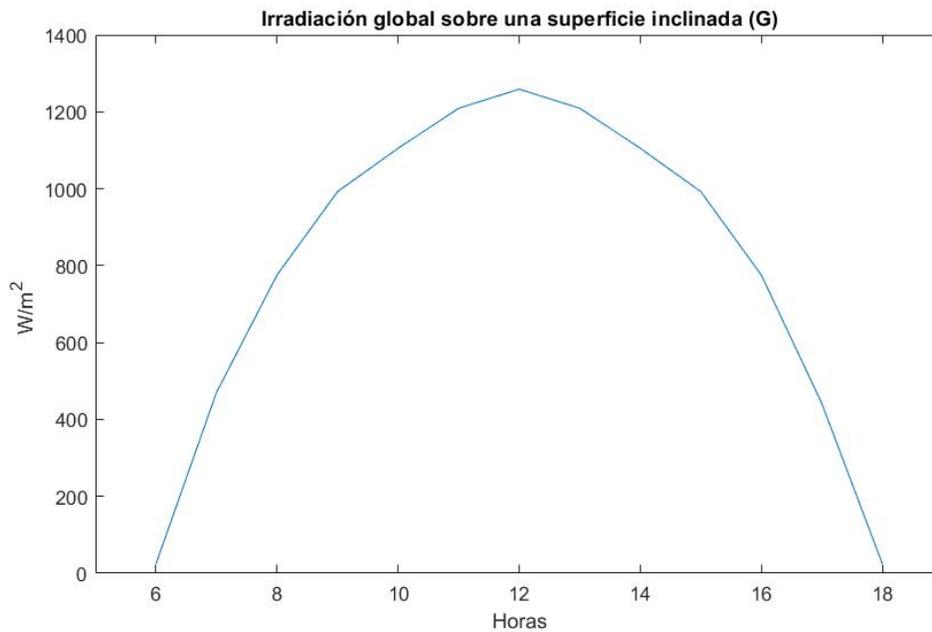


Figura 14. Simulación de irradiación solar global inclinada.

Capítulo 3

Modelos de generación, panel y convertidor

3.1. Sistemas fotovoltaicos

Los sistemas fotovoltaicos son un conjunto de celdas aísla eléctricamente del exterior. Existen diversos tipos de módulos, con diferentes configuraciones eléctricas y características estructurales. En general, estos conjuntos de celdas están encapsulados por dos capas, entre una lámina frontal de vidrio y una capa de termo-plástico. Con frecuencia estos conjuntos son enmarcado en aluminio anodizado, con el fin de incrementar la resistencia mecánica del y facilitar la instalación de los sistemas a las estructuras de soporte (Lamigueiro, 2020).

El encapsulado frontal debe tener y mantener altas propiedades de transmisividad en la banda espectral. A su vez, debe ser resistente a impactos, así como abrasión, otra característica es que la superficie debe ser anti reflexiva, además, su diseño estructural debe ser simple y sin bordes, esto para facilitar su limpieza y disminuir la acumulación de suciedad. Uno de los materiales más utilizados es el vidrio templado, el cual contiene bajos niveles de hierro y propiedades anti reflexivas. Las celdas son encapsuladas al vacío y las capas evitan la presencia de humedad en el módulo puesto que la presencia de esta representa una de las causas principales de la degradación los sistemas fotovoltaicos. Además, esta estructura proporciona altos niveles de aislamiento eléctrico (Lamigueiro, 2020).

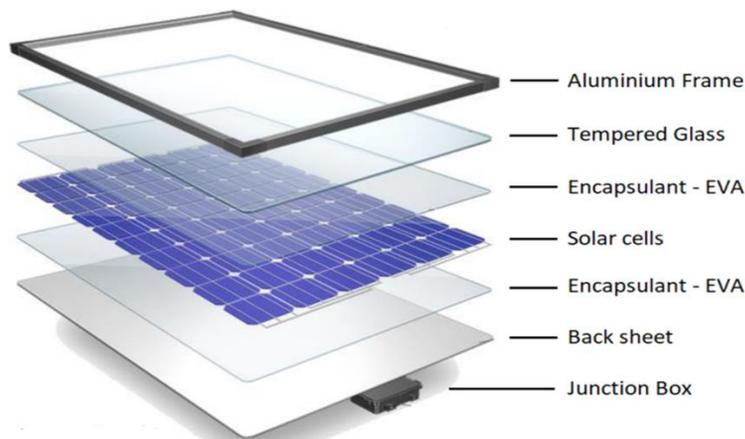


Figura 15. Esquema de elementos fotovoltaicos.

3.2. Factores que afectan la generación de energía

La energía eléctrica obtenida a partir de sistemas fotovoltaicos no solo es afectada por las sombras de árboles o estructuras de gran altitud, uno de los elementos que influye considerablemente en este proceso es la presencia de nubes, generando sombra y difuminando la radiación captada por los paneles solares. Con la presencia de nubosidad, los sistemas fotovoltaicos conectados a la red pública son afectados importantemente puesto que producen fluctuaciones en su producción y desestabilizan la distribución de energía (S kumar, 2018).

La densidad de potencia de la radiación incidente a lo largo del tiempo sobre la superficie inclinada, la cantidad de energía solar por metro cuadrado. El número de horas de sol al año depende de muchos factores; el más importante es la duración del día, las nubes y la transparencia de la atmósfera. La energía solar también depende del grado de sombreado, las capacidades de ubicación de los módulos, los accesorios adicionales, la posibilidad de cableado eléctrico, y en caso de tener que configurar la instalación en el techo o fachada orientación y / o cubiertas inclinadas (P. Bunme, 2020).

3.3. Celda solar

La primera formulación de una celda solar es el modelo ideal de diodo único que se compone de un diodo en paralelo con una fuente de corriente. Sin embargo, el uso de este modelo no refleja el comportamiento real de la celda fotovoltaica. Por lo tanto, para un diseño de celda fotovoltaica más realista, la evaluación de las pérdidas debe tenerse en cuenta agregando un bloque de resistencias al modelo ideal, para diseñar contactos entre el silicio y la superficie de los electrodos, se agrega una resistencia en serie; este modelo se denomina modelo simplificado de diodo único (SSDM) y se aumenta el número de parámetros desconocidos a cuatro sumando la resistencia en serie R_s . La solución matemática requiere cuatro ecuaciones para encontrar la incógnita parámetros. La derivada de la potencia con respecto al voltaje ($\frac{\partial P}{\partial V} = 0$) y las expresiones relativas de los coeficientes de temperatura K_I y/o K_V .

El SSDM se ha utilizado ampliamente para estudiar el rendimiento de la célula fotovoltaica mostrando unos resultados modestos, lo que implicó su mejora al agregar otro parámetro señalado como la resistencia en derivación. En consecuencia, el número de parámetros aumenta a cinco y el proceso de extracción se complica. Este modelo recibe el nombre de modelo detallado de diodo único (SDM) y se considera el más utilizado debido a su mejor compromiso entre eficiencia y simplicidad (C. Yassine, 2019).

En la literatura, se introdujo otra versión del SDM, denominado modelo de doble diodo (DDM) que presenta la misma estructura que el SDM, pero en el que se agrega un segundo diodo al modelo de circuito de la celda fotovoltaica. Gracias a su alto rendimiento, este modelo ha sido adoptado últimamente por varios autores. El DDM asume siete parámetros desconocidos $\{I_L, I_{OS1}, I_{OS2}, R_s, R_{sh}, \gamma_1, \gamma_2\}$ lo que lleva a un proceso de extracción más complicado, ya que necesita un conjunto de siete ecuaciones para ser resuelto. Para superar la complejidad del proceso de determinación de parámetros, se pueden emplear varias técnicas. Los métodos analíticos y metaheurísticos son los enfoques más comunes para

resolver el “problema de estimación de parámetros del modelo de célula fotovoltaica” (C. Yassine, 2019).

3.4. Modelos de celda fotovoltaica

La corriente de salida del modelo simplificado de diodo único se expresa mediante la siguiente ecuación (C. Yassine, 2019):

$$I = I_L - I_{os} \{ \exp[A (V + IR_S) - 1] \} \quad (46)$$

Donde:

I : Corriente fotovoltaica.

V : Voltaje fotovoltaico.

I_L : Corriente fotogenerada.

I_{os} : Corriente de saturación.

R_S : Resistencia en serie.

A : Voltaje térmico.

El modelo detallado de un solo diodo (Figura 11) agrega la resistencia shunt R_{Sh} , lo que con lleva a que la corriente en la celda fotovoltaica se represente de la siguiente manera (C. Yassine, 2019):

$$I = I_L - I_{os} \{ \exp[A (V + IR_S) - 1] \} - \frac{V+R_S I}{R_{Sh}} \quad (47)$$

Para el modelo de diodo doble, mostrado en Figura 12, Ambas corrientes circuladas en los diodos se expresan por separado, por lo tanto, la corriente de salida está dada por la siguiente ecuación (C. Yassine, 2019):

$$I = I_L - I_{os1} \{ \exp[A_1 (V + IR_S) - 1] \} - I_{os2} \{ \exp[A_2 (V + IR_S) - 1] \} - \frac{V+R_S I}{R_{Sh}} \quad (48)$$

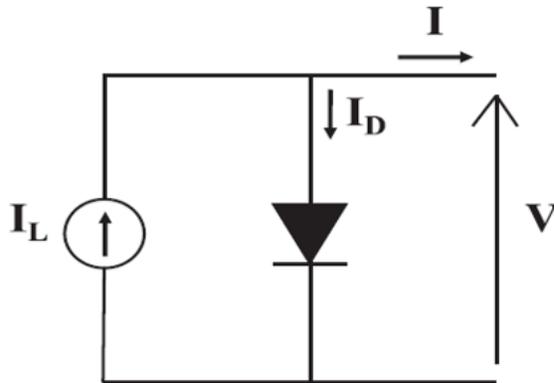


Figura 16. Modelo ideal de diodo único

Capítulo 3. Modelos de generación, panel y convertidor

Características:

- Primera formulación introducida para representar una celda solar.
- El número de parámetros desconocidos es de 4.
- El uso de este modelo no refleja el comportamiento real de la celda fotovoltaica.

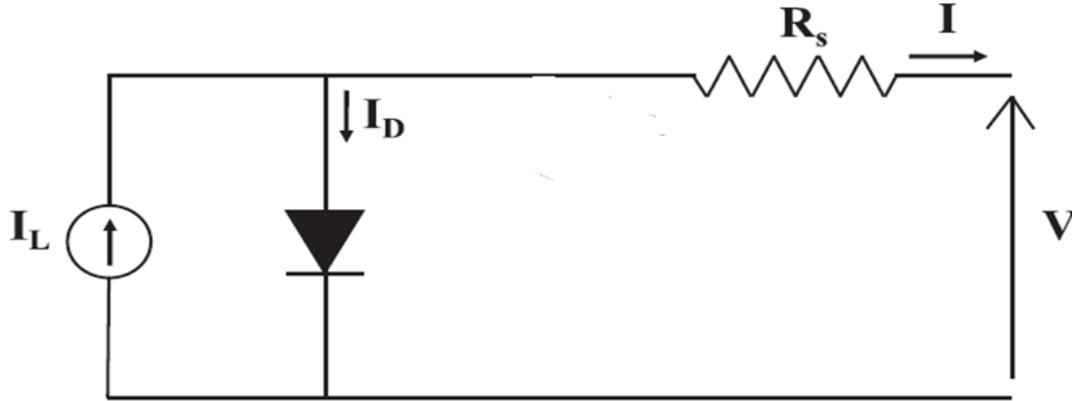


Figura 17. Modelo detallado de diodo único

Características:

- Integra bloque de resistencias para tomar en cuenta las pérdidas.
- Para diseñar contactos entre el silicio y la superficie de los electrodos, se agrega una resistencia en serie.
- El número de parámetros desconocidos es de 5.
- Es el más utilizado para estudiar el rendimiento de la celda fotovoltaica.
- La mayoría de software se basan en este modelo.

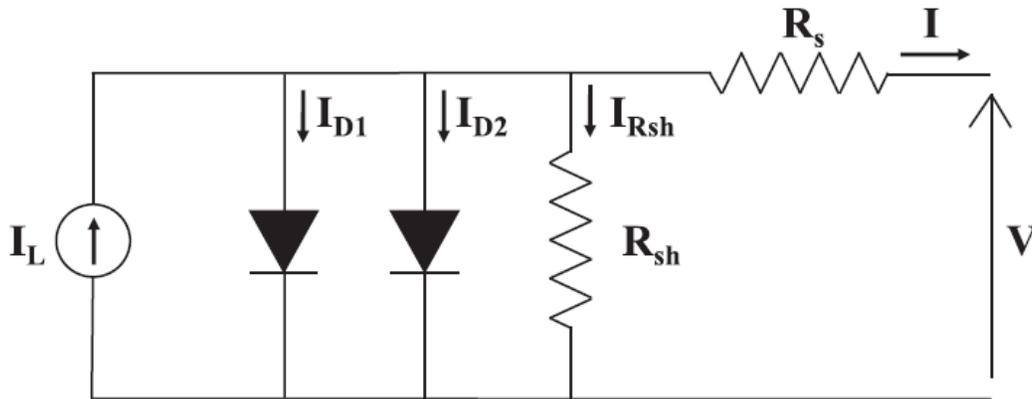


Figura 18. Modelo de doble diodo

Características:

- Es otra versión del SDM.
- Agrega un segundo diodo al modelo de SDM.
- El número de parámetros desconocidos es de 7.
- Su proceso de extracción más complicado.

Para esta tesis el modelo seleccionado para simulaciones y el estudio fue el modelo detallado de diodo único, de acuerdo a (C. Yassine, 2019), según la zona de análisis, tipo de simulación y condiciones climáticas, además de ser el más usado en la literatura, indica que es la mejor opción para esta investigación.

3.5.2. Modelo matemático de panel fotovoltaico

El modelo general de celda solar (PV) es se muestra en la Figura 19. Consiste en la corriente emitida por la radiación, un diodo, una resistencia shunt (R_{sh}) y una resistencia en serie (R_s).

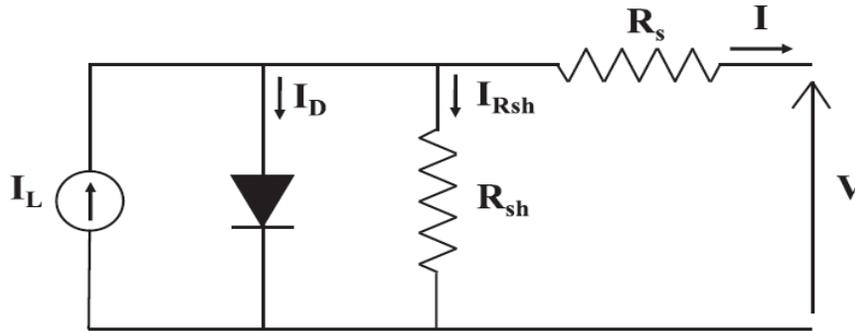


Figura 19. Circuito equivalente de celda solar.

La ecuación de características de corriente y voltaje es (Y. Chaibia, 2019)

$$I = I_L - I_{os} \left\{ \exp \left[\frac{A (V + IR_s)}{nKT} - 1 \right] \right\} - \frac{V + R_s I}{R_{sh}} \quad (49)$$

Donde:

I : Corriente de salida.

V : Voltaje de salida de la celda solar.

I_{os} : Corriente de saturación inversa del diodo.

K : Constantes Boltzmann's. (1.3807×10^{-23}).

R_s : Resistencia en serie de la celda solar.

R_{sh} : Resistencia shunt de la celda solar.

n : Factor de desviación del diodo.

T : Temperatura de la celda.

A : Constante con el valor de 1.6×10^{-19} .

Capítulo 3. Modelos de generación, panel y convertidor

Tabla 6. Tabla de valores.

Voltaje de circuito abierto (voc)	36.30 Volts
Corriente de corto circuito (Isc)	7.84 Amp.
Potencia máxima	213.15 Watt
Voltaje en el máximo punto de potencia	29.00 Volts
Corriente en el máximo punto de potencia	7.35
Fotocorriente	7.8649 Amp.
Corriente de saturación inversa	2.9259×10^{-10} Amp
Resistencia en serie	0.39383 ohm
Resistencia de shunt	313.3991 ohm
Celdas por módulo	60
Factor de idealidad del diodo	0.98117

3.5. Convertidor boost

Los convertidores tienen la capacidad de aumentar un voltaje bajo a un nivel de alto voltaje, por lo tanto, se utilizan diferentes topologías de refuerzo para la acción de refuerzo. El convertidor boost se utiliza como un convertidor elevador para aumentar el voltaje dado al voltaje deseado. La entrada a este convertidor puede ser de cualquier fuente de CC como panel solar, baterías, etc. (N. Boujelben, 2017).

En la figura 16 siguiente se muestra el diagrama representativo de un convertidor tipo boost. El interruptor en el esquema fig. 1, consiste en un elemento de conmutación rápida como un transistor BJT, un Mosfet o el más comúnmente usado el IGBT y un diodo con un tiempo de recuperación mucho menor que el periodo de la señal de control; la función de éste último, es impedir que la corriente de descarga del condensador se devuelva, ya que se desea que cuando la fuente se desconecta del condensador y de la resistencia de carga para almacenar energía en la bobina, se suministre corriente a la carga mediante la descarga del condensador (F. F. Valderrama, 2011).

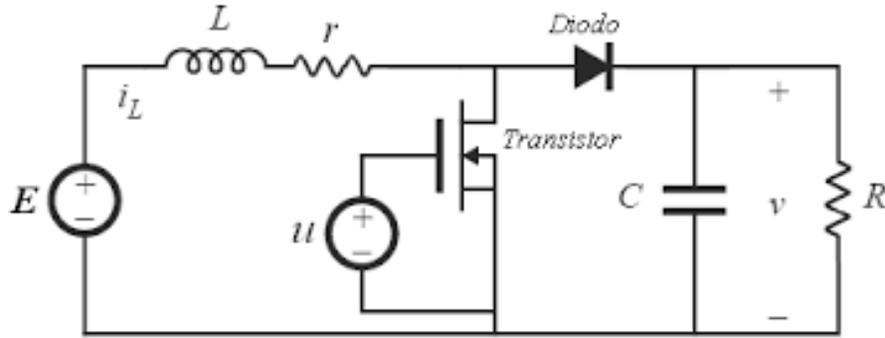


Figura 20. Circuito equivalente de convertidor tipo boost.

$$\frac{di}{dt} = \frac{1}{L}(E - ir - uv) \quad (50)$$

$$\frac{dv}{dt} = \frac{1}{c}(ui + \frac{v}{R}) \quad (51)$$

Donde:

D: Diodo.

C: Capacitor.

v: voltaje.

R: Resistencia.

i: Corriente.

L: Inductancia.

Este esquema consiste en dos estructuras posibles, en estado encendido, el inductor se carga a través de la tensión de alimentación y almacena la energía como se muestra en la figura 17. Durante este estado, la corriente del inductor aumenta gradualmente y en estado apagado, la energía almacenada en el inductor cambia su polaridad para cargar el capacitor a través del diodo como se muestra en la figura 21.

$$E = L \frac{di}{dt} + ir \quad (52)$$

$$c \frac{dv}{dt} = -\frac{v}{R} \quad (53)$$

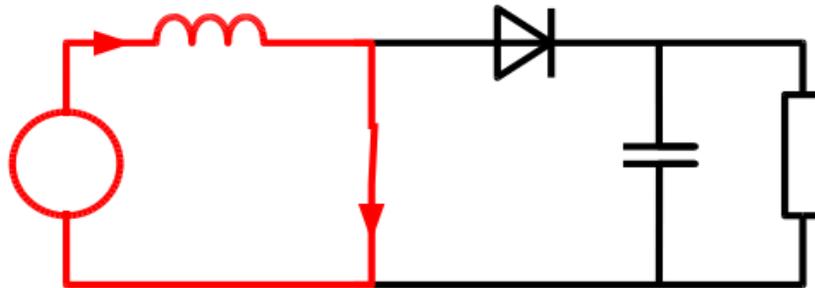


Figura 21. Convertidor boost posición 1.

$$E = L \frac{di}{dt} + ir + v \quad (54)$$

$$i = c \frac{dv}{dt} + \frac{v}{R} \quad (55)$$

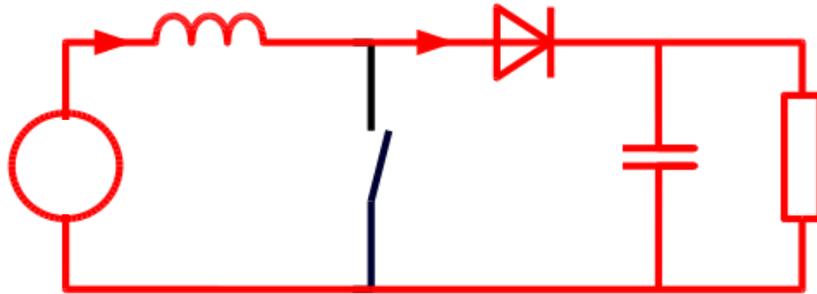


Figura 22. Convertidor boost posición 2.

3.6. Máximo punto de potencia

El sistema de energía renovable requiere un convertidor adecuado, ya que genera energía no regulada. Estos sistemas utilizaban principalmente un convertidor elevador para suministrar alto voltaje a la carga, o para que pueda conectarse a la red eléctrica. La topología intercalada se utiliza en aplicaciones elevadas, ya que tiene numerosas ventajas sobre el convertidor elevador convencional en términos de eficiencia, respuesta transitoria, tamaño de los componentes y emisión electromagnética conducida. Los convertidores de electrónica de potencia con sistemas de seguimiento del punto de máxima potencia (MPPT) se utilizan para regular la energía eléctrica generada por la célula solar. Un convertidor sin sistema MPPT solo regula la tensión de salida del módulo fotovoltaico, pero no garantiza que el sistema fotovoltaico esté funcionando en el punto de máxima potencia MPPT (S. K. Singh, 2015).

Para implementar este algoritmo el voltaje se detecta como entrada al controlador MPPT. Al usar este algoritmo, la potencia de salida se verifica aumentando o disminuyendo el voltaje. Si la potencia aumenta, entonces tenemos que detectar el voltaje si el voltaje también aumenta, entonces tenemos que reducir la relación de trabajo, si el voltaje se reduce aún más, entonces tiene que aumentar la relación de trabajo (S. S. Manna, 2020). En la figura 19 se muestra el algoritmo que representa esta lo antes mencionado.

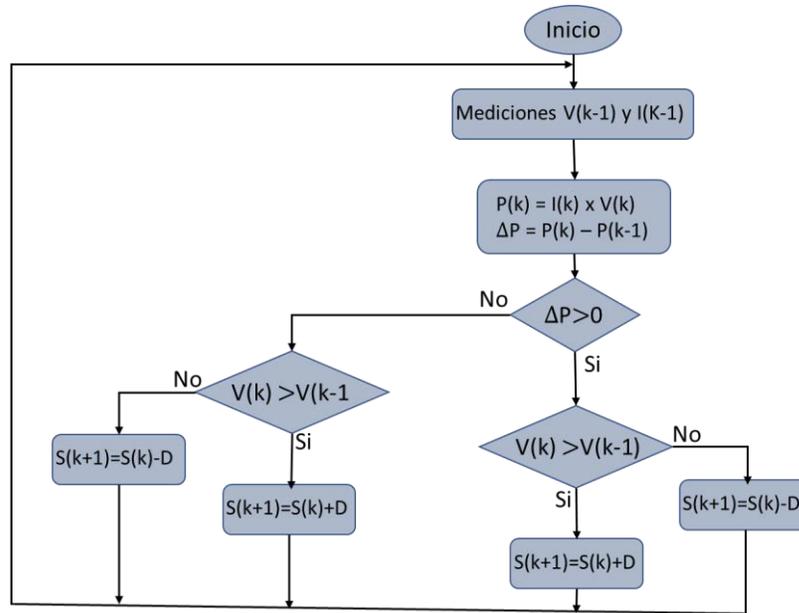


Figura 23. Algoritmo MPPT.

Característica del panel solar ante variaciones de carga:

Los sistemas fotovoltaicos se pueden considerar como una fuente de alimentación variable, esto puesto que realizar variaciones a la carga conectada entre sus terminales. El punto de máxima potencia (MPPT) que proporciona cierta curva y una carga determinada, se conserva, mientras se mantengan las condiciones de irradiación y temperatura (S. Singh, 2020).

Utilización del convertidor como adaptador de impedancia para el panel solar con MPPT.

Tomando en cuenta el análisis realizado anteriormente, al conectar el panel fotovoltaico a una carga a través del convertidor, la impedancia y la carga se adaptan, de forma que la impedancia pueda entregar siempre la máxima potencia de la carga.

Lo que nos lleva a que, al tener una determinada carga, una condición de radiación constante y una temperatura, el ciclo de trabajo del convertidor se mantendría a un cierto valor de operación en el MPPT, no obstante, en caso de que alguna de las condiciones cambiara, el ciclo de trabajo compensaría dicho cambio y así mantenerse en el MPPT.

3.7. Algoritmos de MPPT seleccionados

Las técnicas más utilizadas y difundidas en la literatura científica son las de “Perturbar y Observar” (P&O), “Hill-Climbing” (HC), “Conductancia Incremental” (IC), “Fuzzy Logic”, “Redes Neuronales” y “Tensión Constante”. Para ésta tesis se eligió la IC, proporciona mayor eficiencia y menor costo computacional (G. Y. Aguirre, 2014).

La técnica IC se basa en la curva generada de la potencia con respecto a la tensión. Al analizar el punto de máxima potencia, la derivada de la potencia respecto de la tensión es nula (G. Y. Aguirre, 2014), con esto se crea el algoritmo de decisión. El algoritmo mencionado se puede observar en el diagrama de flujo, mostrado en la figura 23, que la carga computacional es

Capítulo 3. Modelos de generación, panel y convertidor

reducida, por lo cual, puede ser utilizado con elevadas frecuencias de muestreo de las variables, de ser necesario.

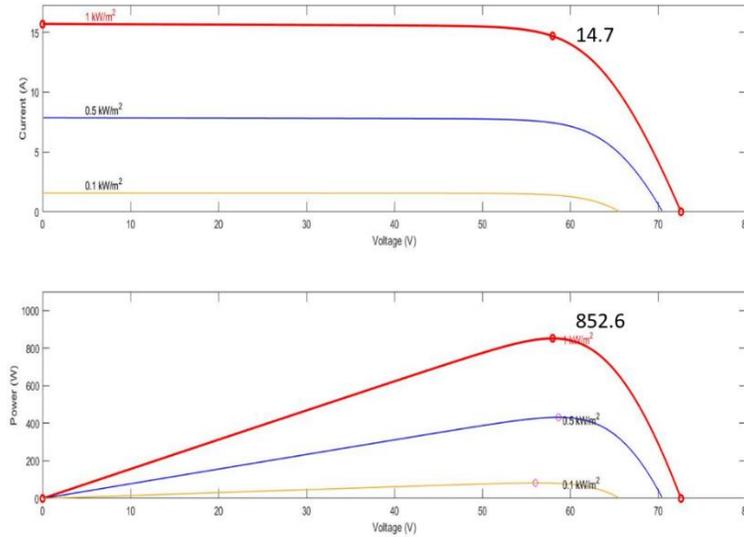


Figura 24. MPPT.

El MPPT es un algoritmo inteligente que garantiza que el sistema fotovoltaico esté funcionando en el MPP en cualquier condición, para esto se realizó un algoritmo de MPPT de conductancia incremental (S. Singh, 2020).

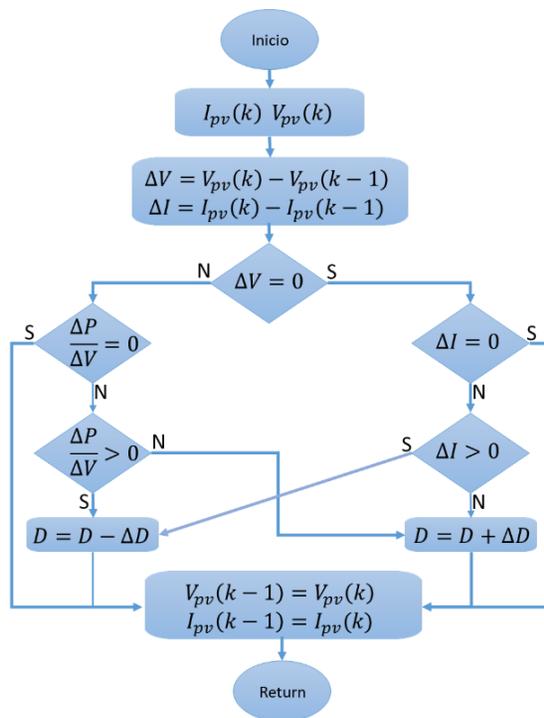


Figura 25. Algoritmo MPPT.

Capítulo 4

Nubosidad y predicción de nubosidad con ANN

4.1 Nubosidad

La nubosidad se refiere a la fracción de cielo que se encuentra cubierto por nubes, las cuales están constituidas por partículas de agua o hielo, según la temperatura de la nube. La manera en que las nubes se distribuyen sobre una determinada región depende de la topografía, altitud y distancia de la línea costera (R. G. Coronel, 2017).

4.2. Patrones nubosos

Con base en los avances tecnológicos e investigaciones sobre la nubosidad, así como de su comportamiento, ha sido posible avanzar en la recaudación de información sobre esta. La nubosidad en general es fuertemente influenciada por diversos factores, como, el viento, la temperatura, altitud, entre otros y que a su vez afecta de formas diferentes. Por lo antes mencionado, es posible obtener imágenes satelitales en las cuales se obtienen datos, analizando los patrones nubosos y con ello aportando información para la prevención y solución de los posibles cambios que conlleven la presencia de nubosidad (J. Melgarejo L. Romero, 2015).

4.3. Clasificación básica

Cuando hablamos de clasificación de nubosidad podemos decir que se dividen en dos grandes familias, esto con el fin de clasificar de forma correcta la estructura de cada una de ellas. Las clasificaciones de estas están formadas por nubes estratiformes y cumuliformes(J. Melgarejo L. Romero, 2015).

- Nubosidad cumuliforme

La nubosidad cumuliforme tiene las características de poseer altos niveles de turbulencia en su interior y se desarrollan de forma vertical en grandes extensiones y la lluvia que producen es de fuerte intensidad y de forma local, se presentan de forma líquida, sólida o mixta.

- Nubosidad estratiforme

Capítulo 4. Nubosidad y predicción de nubosidad con ANN

Esta nubosidad tiene la forma de un manto de poco espesor vertical, usualmente se presenta en zonas de valles y esta es claramente apreciable desde la zona terrestre, la lluvia que provoca es de forma leve y continua.

Otra clasificación de las nubes es por la altura, la cual se divide en:

- Nubes altas: estas se encuentran a una altura superior a los 6Km y están compuestas por cristales de hielo.
- Nubes medias: se encuentran a una altura de entre 2Km y 4Km en la zona de polos, entre 2Km y 7Km en latitudes centrales y entre 2Km y 8Km en zonas del trópico, están compuestas por cristales y gotas de agua.
- Nubes bajas: se encuentran a una altura máxima de 2Km y están compuestas por gotas de agua líquidas.



Figura 26. Tipos de nubes

4.4. Imágenes satelitales

Las imágenes satelitales son espectros que proporcionan diversos tipos de información meteorológica, con estas es posible analizar de una forma más adecuada el comportamiento de la nubosidad; en las imágenes satelitales los cúmulos de nubosidad estratiformes se visualizan como un manto lechoso y una estructura suave; los cumuliformes se visualizan de forma abultada sedosa y fibrosa (J. Melgarejo L. Romero, 2015).

4.5. Teledetección de nubosidad

La teledetección de nubosidad es la detección de información de nubosidad, de forma no invasiva, los satélites, radares, entre otros son algunas de las herramientas utilizadas para la teledetección, estos hacen uso de una serie de sensores los cuales están diseñados para captar la radiación emitidas por los satélites y radares. La teledetección actualmente son utilizados

Capítulo 4. Nubosidad y predicción de nubosidad con ANN

como una herramienta para el relevamiento de suelos, recursos forestales, estudios geológicos, geomorfológicos, hidrológicos, urbanismo y una serie de usos más, siendo la de interés los del tipo meteorológico (J. Melgarejo L. Romero, 2015).

En la teledetección remota existen dos tipos:

- Teledetectores pasivos.

Son aquellos que detectan la radiación natural emitida o reflejada por el objeto o el área circundante. La radiación reflejada es más comúnmente obtenida por esta clase de teledetección en general mayormente utilizada para obtener imágenes infrarrojas.

- Teledetectores activos.

Se encargan de emitir energía para poder escanear objetos y áreas, por ejemplo, el sistema usado por los radares. Con este tipo de imágenes es posible visualizar fenómenos climáticos, y comportamientos climáticos los cuales pueden ser analizados de forma global (J. Melgarejo L. Romero, 2015).

4.6. Tipos de imágenes satelitales

- Radiación infrarroja (IR)

En este canal, la reflectividad para la mayoría de los cuerpos es prácticamente nula, los cuerpos mayormente captados por este tipo de señales son los mantos acuíferos, los mantos terrestres y los cuerpos nubosos espesos. Las imágenes IR son utilizadas para observar temperaturas de los cuerpos nubosos, coberturas nubosas, además de que pueden obtener imágenes nocturnas. En una imagen IR, los cuerpos más oscuros representan temperaturas calientes y los cuerpos mayormente claros temperaturas frías.

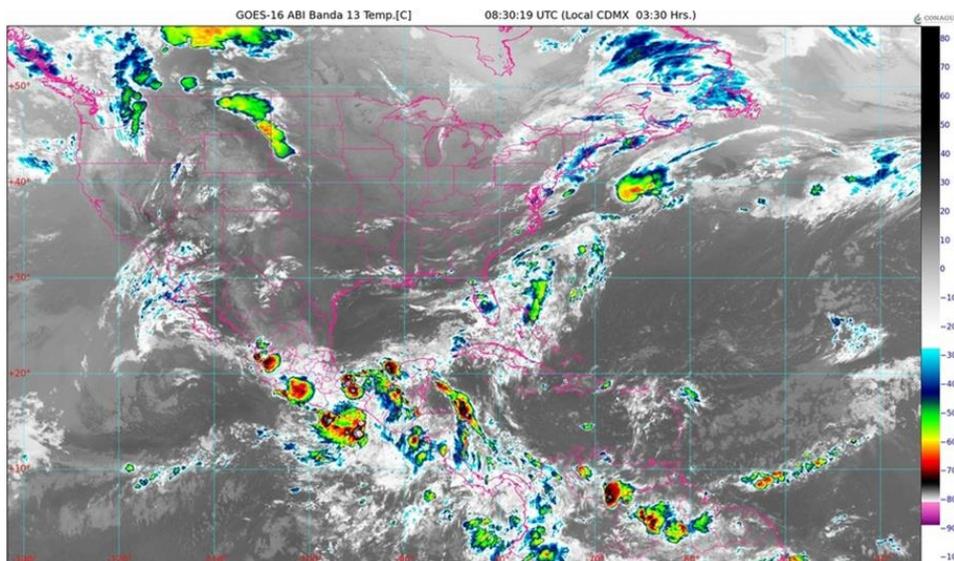


Figura 27. Imagen de radiación infrarroja.

Capítulo 4. Nubosidad y predicción de nubosidad con ANN

▪ VAPOR DE AGUA

Este tipo de imágenes suelen ser utilizadas para analizar el nivel de agua en una zona, son útiles para observar zonas de aire húmedo y seco. Los colores oscuros en las imágenes representan aire seco, mientras que los colores más brillantes indican aire húmedo.

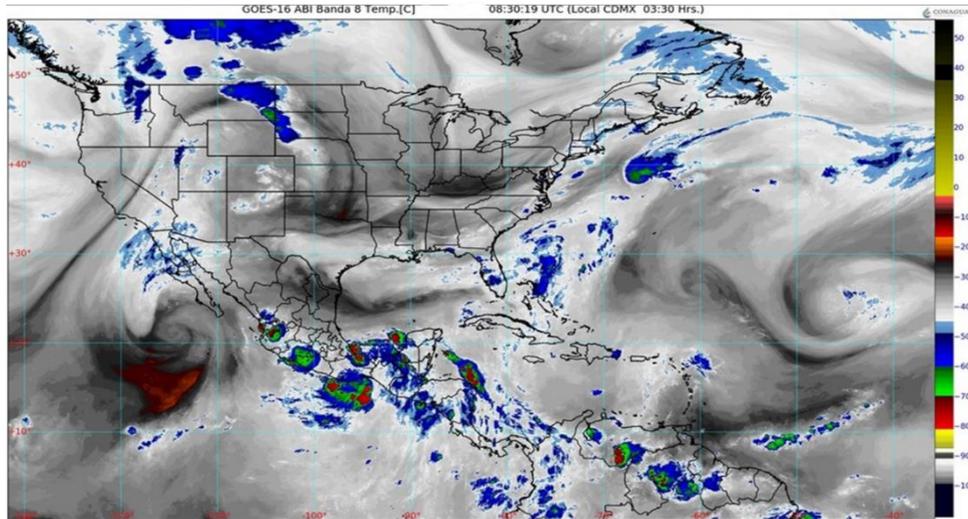


Figura 28. Imagen vapor de agua.

▪ VISIBLE

Este tipo de imágenes obtienen la nubosidad reflejada por la luz solar y no son posibles de obtener imágenes nocturnas, en este tipo de imágenes las nubes de mayor espesor tienen mayor brillo que las nubes de menor espesor; en ocasiones es complicado distinguir entre nubes bajas, medias y altas, ya que su albedo es similar, por ellos para realizar esta distinción, se utilizan imágenes tipo IR (J. Melgarejo L. Romero, 2015).

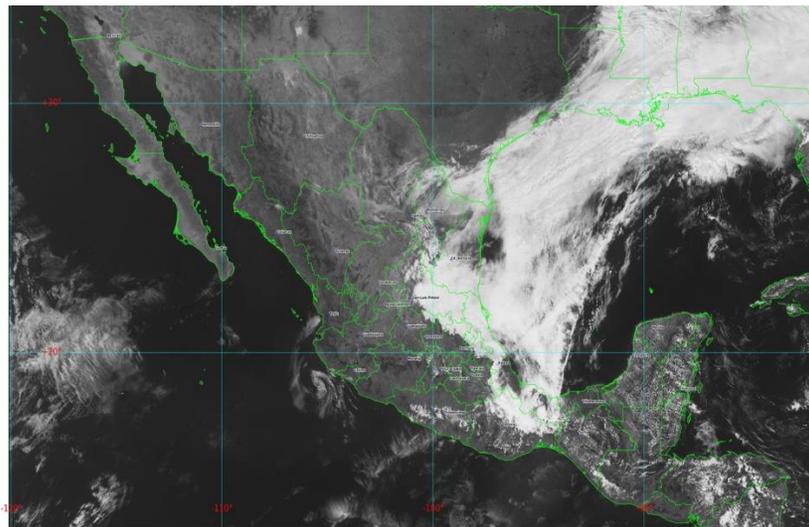


Figura 29. Imagen visible.

4.7. Redes neuronales

Las redes neuronales no son más que un conjunto de neuronas las cuales realizan un procesamiento independiente, el cual posteriormente es transmitido de neurona en neurona para después realizar una acción a través del sistema nervioso. En general una neurona esta compuesta por dendritas, que tienen el objetivo de captar impulsos nerviosos, el soma capaz de procesar la información y enviándola a través del axón.

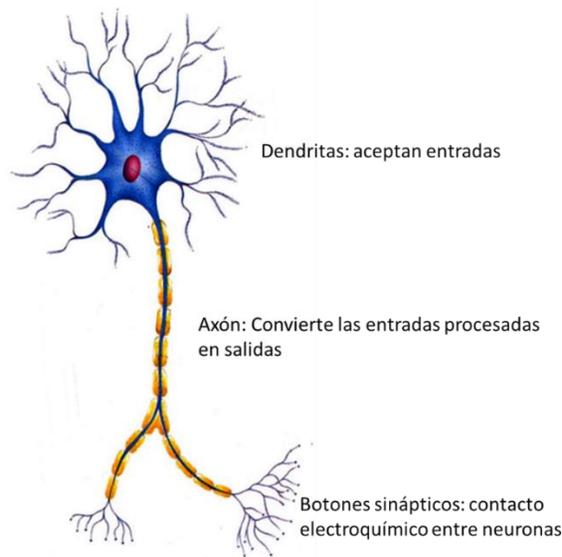


Figura 30 Neurona biológica

Dentro de los humanos hay muchas variaciones en este tipo básico de neurona, lo que complica aún más los intentos del hombre de replicar eléctricamente el proceso del pensamiento. Sin embargo, todas las neuronas naturales tienen los mismos componentes básicos. Estos componentes se conocen por sus nombres biológicos: dendritas, axón y sinapsis.

Las dendritas son extensiones del soma con forma de cabello que actúan como canales de entrada. Estos canales de entrada reciben su entrada a través de las sinapsis de otras neuronas, el soma procesa estas señales entrantes a lo largo del tiempo, luego, el soma convierte ese valor procesado en una salida que se envía a otras neuronas a través del axón y las sinapsis como podemos observar en la figura anterior.

Las neuronas se comunican a través de señales eléctricas que son impulsos de corta duración o "picos" en el voltaje de la pared o membrana celular. Las conexiones entre neuronas están mediadas por uniones electroquímicas llamadas sinapsis, que se encuentran en ramas de la célula denominadas dendritas. Cada neurona recibe típicamente muchos miles de conexiones de otras neuronas y, por lo tanto, recibe constantemente una multitud de señales entrantes, que finalmente llegan al cuerpo celular. Aquí, se integran o se suman de alguna manera y, en términos generales, si la señal resultante excede algún umbral, la neurona se "disparará" o generará un impulso de voltaje en respuesta. Esto luego se transmite a otras neuronas a través de una fibra ramificada conocida como axón.

Capítulo 4. Nubosidad y predicción de nubosidad con ANN

Para determinar si se debe producir un impulso o no, algunas señales entrantes producen un efecto inhibitorio y tienden a evitar el disparo, mientras que otras son excitadoras y promueven la generación de impulsos. Se supone que la capacidad de procesamiento distintiva de cada neurona reside en el tipo (excitador o inhibitorio) y la fuerza de sus conexiones sinápticas con otras neuronas. Es esta arquitectura y estilo de procesamiento lo que esperamos incorporar en las redes neuronales y, debido al énfasis en la importancia de las conexiones interneuronales, este tipo de sistema a veces se denomina conexionista y el estudio de este enfoque general como conexionismo.

Esta terminología es a menudo la que se encuentra para las redes neuronales en el contexto de modelos inspirados psicológicamente de la función cognitiva humana. Sin embargo, lo usaremos de manera bastante general para referirnos a redes neuronales sin hacer referencia a ningún campo de aplicación en particular (Gurney, 2004).

Los equivalentes artificiales de neuronas biológicas son los nodos o unidades. Las sinapsis se modelan mediante un solo número o peso, de modo que cada entrada se multiplica por un peso antes de enviarse al equivalente del cuerpo celular. Aquí, las señales ponderadas se suman mediante una simple suma aritmética para proporcionar una activación de nodo. La llamada unidad lógica de umbral (TLU), la activación se compara con un umbral; si la activación excede el umbral, la unidad produce una salida de alto valor (convencionalmente "1"), de lo contrario, produce cero (Gurney, 2004).

4.7.1. Neurona artificial

Una red neuronal artificial o ANN por sus siglas en inglés artificial neuronal network (ANN) es un modelo matemático que intenta simular la estructura y funcionalidades de las redes neuronales biológicas. El bloque de construcción básico de cada red neuronal artificial es una neurona artificial, es decir, un modelo matemático simple (función). Dicho modelo tiene tres conjuntos de reglas simples: multiplicación, suma y activación. A la entrada de la neurona artificial, las entradas se ponderan, lo que significa que cada valor de entrada se multiplica por el peso individual. En la sección central de la neurona artificial está la función de suma que suma todas las entradas ponderadas y el sesgo. A la salida de la neurona artificial, la suma de las entradas previamente ponderadas y el sesgo pasa a través de la función de activación que también se llama función de transferencia. La neurona artificial es un componente básico de toda red neuronal artificial. Su diseño y funcionalidades se derivan de la observación de una neurona biológica que es el componente básico de las redes (sistemas) neuronales biológicos que incluye el cerebro, la médula espinal y los ganglios periféricos (Suzuki, 2011).

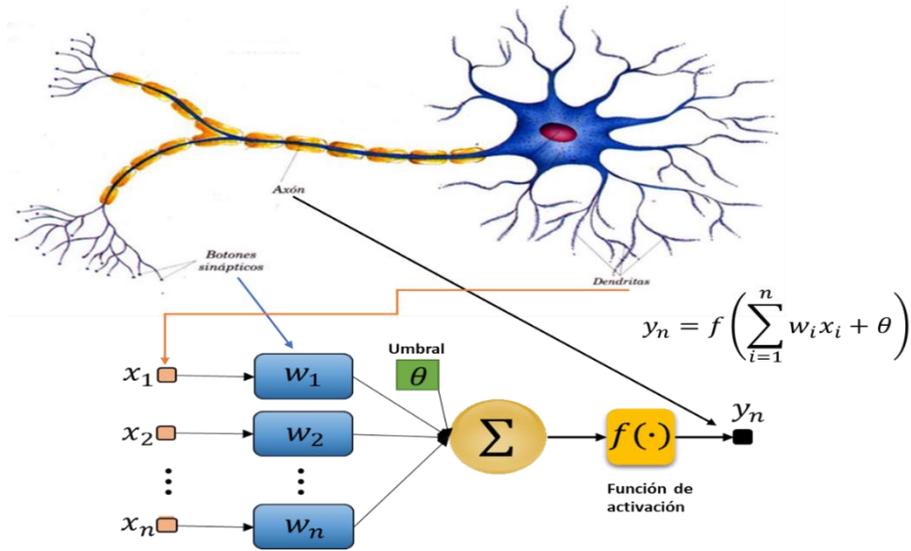


Figura 31. Red neuronal biológica y artificial.

4.7.2. Redes neuronales artificiales y cómo funcionan

Al combinar dos o más neuronas artificiales estamos obteniendo una red neuronal artificial. Si una sola neurona artificial casi no tiene utilidad para resolver problemas de la vida real, las redes neuronales artificiales la tienen. De hecho, las redes neuronales artificiales son capaces de resolver problemas complejos de la vida real procesando información en sus bloques de construcción básicos (neuronas artificiales) de forma no lineal, distribuida, paralela y local. La forma en que se interconectan las neuronas artificiales individuales se denomina topología, arquitectura o gráfico de una red neuronal artificial (Suzuki, 2011).

El hecho de que la interconexión se pueda realizar de diversas formas da como resultado numerosas topologías posibles que se dividen en dos clases básicas. Mismas que se dividen en dos topologías; topología de avance simple (gráfico acíclico) donde la información fluye de las entradas a las salidas en una sola dirección y topología recurrente simple (gráfico semi cíclico) donde parte de la información fluye no solo en una dirección de entrada a salida, sino también en dirección opuesta. Debemos mencionar que, para facilitar el manejo y la descripción matemática de una red neuronal artificial, agrupamos neuronas individuales en capas (Suzuki, 2011).

La capacidad de procesamiento de la red se almacena en las fortalezas de conexión entre unidades, o ponderaciones, obtenidas mediante un proceso de adaptación o aprendizaje de un conjunto de patrones de entrenamiento.

Capítulo 4. Nubosidad y predicción de nubosidad con ANN

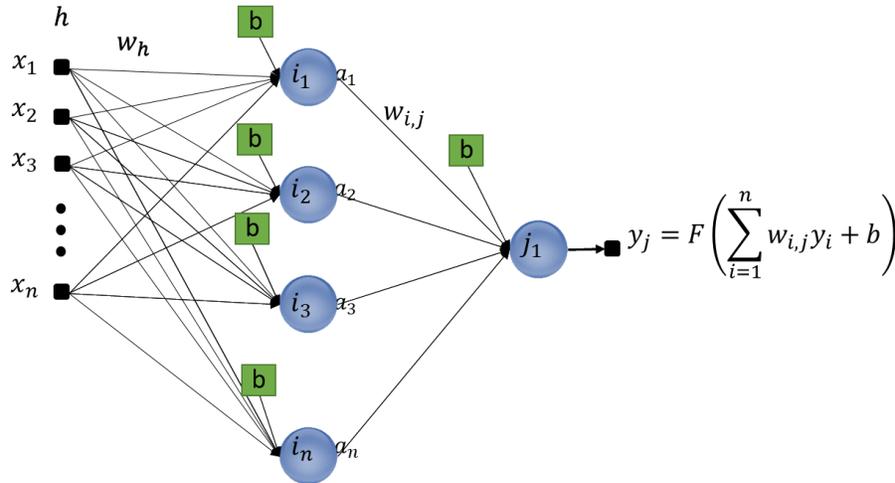


Figura 32. Red neuronal artificial feed forward.

4.7.3. Tipos de redes Neuronales artificiales

Teniendo en cuenta el flujo de datos, podemos distinguir entre redes unidireccionales (feedforward) y redes recurrentes o realimentadas (feedback). Mientras que en las redes unidireccionales la información circula en un único sentido, en las redes recurrentes o realimentadas la información puede circular entre las distintas capas de neuronas en cualquier sentido, incluso en el de salida-entrada.

4.7.4. Entrenamiento de una red neuronal artificial

Una vez que se ha estructurado una red para una aplicación en particular, esa red está lista para ser entrenada. Para iniciar este proceso, los pesos iniciales se eligen al azar. Entonces, comienza el entrenamiento o aprendizaje. Básicamente, la mayoría de las aplicaciones de las redes neuronales se incluyen en las siguientes cinco categorías (Vega-Carrillo, 2007):

- predicción
- clasificación
- asociación de datos
- conceptualización de datos
- filtrado de datos

Tabla 4. Resumen de estado del arte

Tipo de red	Aprendizaje	Descripción
Predicción	<ul style="list-style-type: none"> - Back-propagation - Delta Bar Delta - Extended delta bar delta - Directed random search - Higher order Neural Networks 	Utiliza valores de entrada para predecir algunos resultados (por ejemplo, elija las mejores acciones del mercado de valores, prediga el clima, identifique personas con riesgo de cáncer)

Capítulo 4. Nubosidad y predicción de nubosidad con ANN

	- Self Organizing Map into Backpropagation	
Clasificación	- Learning vector quantization - Counter-propagation - Probabilistic neural network	Utiliza valores de entrada para determinar la clasificación (por ejemplo, si la entrada es la letra A, el conjunto de datos de video de un avión y ¿Qué tipo de avión es?
Asociación de datos	- Hopfield - Boltzmann Machine - Hamming network - Bidirectional associative memory - Spatio-temporal pattern recognition	Al igual que la clasificación, pero también reconoce los datos que contienen errores (por ejemplo, no solo identifica los caracteres que se escanearon, sino que también identifica cuándo el escáner no funcionaba correctamente)
Conceptualización de datos	- Adaptive resonance Network - Self organizing map	Analizar las entradas para que se puedan inferir las relaciones de agrupación (Extraer de una base de datos los nombres de quienes tienen más probabilidades de comprar un producto en particular)
Filtrado de datos	- Recirculation	Suavizar una señal de entrada (por ejemplo, eliminar el ruido de una señal telefónica)

4.7.5. Redes neuronales artificiales para predicción

El uso más común de las redes neuronales es proyectar lo que es más probable que suceda. Hay muchas aplicaciones en las que la predicción puede ayudar a establecer prioridades. Por ejemplo, la sala de emergencias de un hospital puede ser un lugar agitado. Saber quién necesita la ayuda más urgente puede permitir una operación más exitosa. Básicamente, todas las organizaciones deben establecer prioridades que rigen la asignación de sus recursos. Esta proyección de futuro es lo que impulsó la creación de redes de predicción (Vega-Carrillo, 2007).

Feedforward, Back-Propagation.

Actualmente, esta arquitectura de retro propagación desarrollada sinérgicamente, es el modelo más popular, eficaz y fácil de aprender para redes complejas de múltiples capas. Esta red se utiliza más que todas las demás combinadas. Se utiliza en muchos tipos diferentes de aplicaciones. Esta arquitectura ha generado una gran clase de tipos de redes con muchas topologías y métodos de entrenamiento diferentes. Su mayor fortaleza está en las soluciones no lineales a problemas mal definidos. La red típica de retro propagación tiene una capa de entrada, una capa de salida y al menos una capa oculta. No existe un límite teórico en el número de capas ocultas, pero normalmente solo hay una o dos. Se han realizado algunos

Capítulo 4. Nubosidad y predicción de nubosidad con ANN

trabajos que indican que se requieren un máximo de cuatro capas (tres capas ocultas más una capa de salida) para resolver problemas de cualquier complejidad.

Las capas de entrada y salida indican el flujo de información durante la recuperación. Recordar es el proceso de poner datos de entrada en una red entrenada y recibir la respuesta. La propagación hacia atrás no se usa durante la recuperación, sino solo cuando la red está aprendiendo un conjunto de entrenamiento.

El número de capas y el número de elementos de procesamiento por capa son decisiones importantes. No existe una respuesta cuantificable y óptima al diseño de la red para una aplicación en particular. Solo hay reglas generales recogidas con el tiempo y seguidas por la mayoría de los investigadores e ingenieros que aplican esta arquitectura a sus problemas (Vega-Carrillo, 2007).

Regla uno: A medida que aumenta la complejidad en la relación entre los datos de entrada y la salida deseada, también debería aumentar el número de elementos de procesamiento en la capa oculta.

Regla dos: Si el proceso que se está modelando se puede separar en varias etapas, es posible que se requieran capas ocultas adicionales. Si el proceso no se puede separar en etapas, entonces las capas adicionales pueden simplemente permitir la memorización y no una verdadera solución general.

Regla tres: La cantidad de datos de entrenamiento disponibles establece un límite superior para el número de elementos de procesamiento en las capas ocultas. Para calcular este límite superior, use el número de ejemplos de pares de entrada-salida en el conjunto de entrenamiento y divida ese número por el número total de elementos de procesamiento de entrada y salida en la red. Luego, divida ese resultado nuevamente por un factor de escala entre cinco y diez. Se utilizan factores de escala más grandes para datos relativamente ruidosos.

Los datos extremadamente ruidosos pueden requerir un factor de veinte o incluso cincuenta, mientras que los datos de entrada muy limpios con una relación exacta con la salida pueden reducir el factor a alrededor de dos. Es importante que las capas ocultas tengan pocos elementos de procesamiento. Se memorizarán demasiadas neuronas artificiales y el conjunto de entrenamiento. Si eso sucede, no se producirá una generalización de las tendencias de los datos, lo que hará que la red sea inútil para los nuevos conjuntos de datos (Vega-Carrillo, 2007).

Capítulo 5

Pruebas y resultados de predicción

En este capítulo se presenta de forma detallada el procedimiento empleado para la resolución del tema de investigación, primero se mencionará el planteamiento del problema el cual tiene como meta realizar una estimación de la capacidad de generación de energía eléctrica producida por sistemas fotovoltaicos, utilizando datos extraídos de la red, tratamiento de imágenes en escala de grises, modelos matemáticos y redes neuronales. Una vez explicada la problemática y las limitaciones que hay en la investigación se plantea una hipótesis la cual indicaría una solución. Se describe de manera detallada el procedimiento de predicción y la aplicación de los datos predichos en los modelos matemáticos.

5.1. Caso de estudio: Niveles de nubosidad e irradiación en coordenadas – Jiutepec Morelos 99.1587,18.8851

La irradiación solar pasa por una serie de procesos para llegar al suelo terrestre, estos procesos obstruyen, *difuminan* y *reflejan* la irradiación en ciertas zonas, esto provoca cambios en los niveles de irradiación especialmente en elementos productores de energía a partir de la irradiación solar.

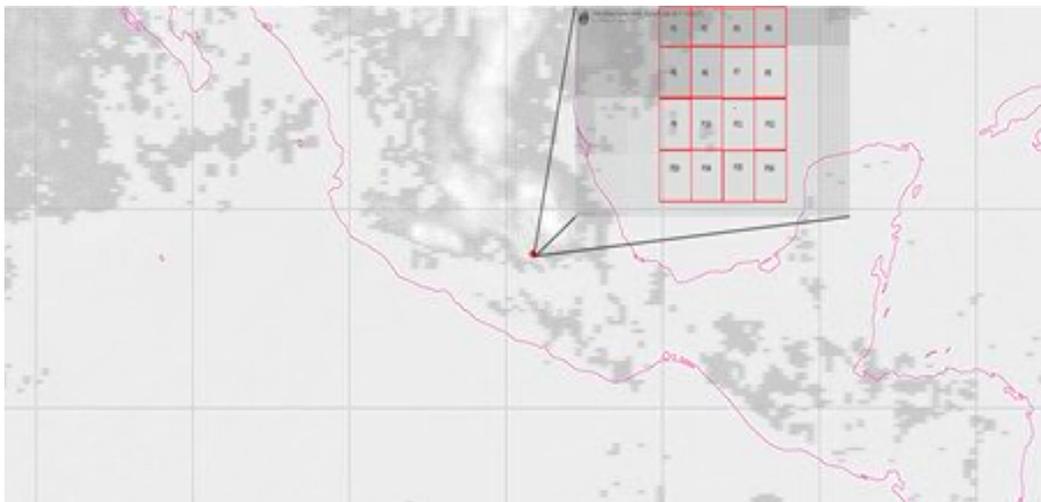


Figura 33. Zona de análisis.

Capítulo 5. Pruebas y resultados de predicción

La irradiación solar global no es más que la suma de los cambios que experimenta la irradiación según las condiciones en una zona determinada y los objetos que captan esta irradiación cambian según la posición en la que se encuentren, es decir el cálculo de la irradiación puede ser dividida en *irradiación global sobre una superficie horizontal* e *irradiación solar sobre una superficie inclinada*, las cuales analizan los diferentes efectos que sufre la irradiación solar en un punto determinado.

La radiación solar global en superficies horizontales (I_H) puede ser medida con un piranómetro, que es un instrumento que mide la radiación solar global desde todas las direcciones. La radiación solar global en superficies horizontales está compuesta por la suma de la irradiación solar directa (I_b) e irradiación solar difusa (I_d) (S. A. Mousavi Maleki, 2017).

$$I_H = I_d + I_b \quad (50)$$

5.2. Limitaciones

Esta tesis se enfoca a realizar predicciones de nubosidad, sin embargo, estas predicciones a pesar de obtener resultados adecuados con el método, el análisis de los niveles de nubosidad representa un estudio más detallado, por lo cual para esta tesis no se tomarán en cuenta las diversas clasificaciones de nubosidad.

5.3. Propuesta de solución para la predicción de nubosidad

Para realizar la predicción de nubosidad se utilizó una red neuronal tipo feed-forward a la cual se le aportaron datos extraídos de imágenes satelitales a las cuales se le aplicó una serie de tratamiento para la obtención de la información, la red neuronal artificial fue entrenada por medio de bloques de datos en concatenando los datos en secciones de horas y aportando el estado de nubosidad en el siguiente instante de tiempo.

A continuación, en las siguientes secciones se desglosará detalladamente el desarrollo antes mencionado para la realización de predicciones de nubosidad.

5.4. Adquisición de datos y tratamiento de imágenes

Para la extracción de imágenes satelitales fueron obtenidas de Global Satellite Mapping of Precipitation (GSMaP) y JAXA Global Rainfall Watch (GSMaP) extrayendo hora a hora cada una imagen satelital en formato Portable Network Graphics (PNG) formato con el cual se obtiene la mayor información en una imagen. Como punto de observación las imágenes fueron centradas en el Instituto Mexicano de Tecnología del Agua (IMTA) ya que es en ese lugar es donde se extrajo la información de irradiación solar en la cual se basó esta tesis.

Las imágenes extraídas posteriormente fueron analizadas en un cuadrante de 4x4 píxeles, en el cual abarca los municipios de Huitzilac, Tepoztlán, Yautepec, Emiliano Zapata,

Capítulo 5. Pruebas y resultados de predicción

Xochitepec, Temixco, Jiutepec y Cuernavaca del estado de Morelos como se muestra en la figura 2.

Una vez señalada la zona de análisis se cambia a un mapa en blanco para solo visualizar la tonalidad de nubosidad como se muestra en la figura 21, este cambio se realiza puesto que se analiza la tonalidad en cada sector del cuadrante seleccionado y el mapa en blanco beneficia este análisis, es importante resaltar que a pesar que la imagen extraída solo tiene tonalidades grises, al realizar en análisis los datos que se proporcionan son de tipo RGB, por lo cual para estandarizar el análisis de los datos extraído es importante aplicar el tratamiento en escala de grises.

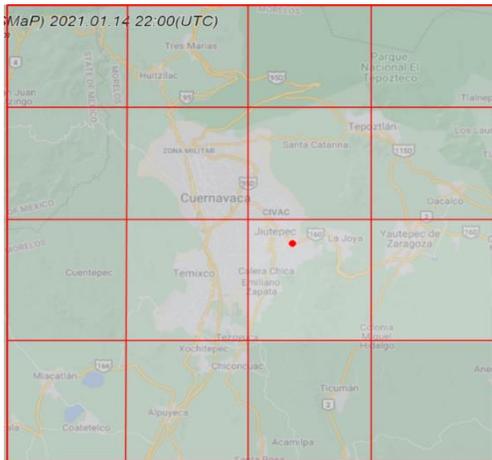


Figura 34. Cuadrante de análisis 1.

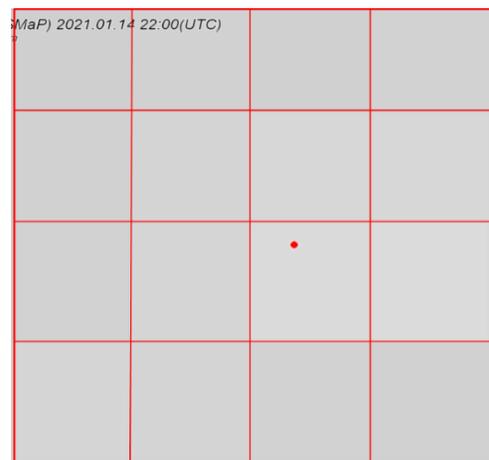


Figura 35. Cuadrante de análisis 2.

El tratamiento de imágenes se realizó de la siguiente forma:

1. Se selecciona la imagen de la hora a la cual se va a realizar el tratamiento:
La hora del día es importante puesto que más adelante se analiza en conjunto con una hora determinada de irradiación solar, para esta tesis la irradiación solar se analiza cada hora a lo largo del día, por lo que se tiene que verificar si los datos que se analizarán se tienen en el mismo momento para los niveles de irradiación.

El analizar la hora en conjunto con el momento de la muestra de los niveles de irradiación solo se realiza para el entrenamiento de la red neuronal 2, para realizar predicciones no es necesario tener los niveles de irradiación puesto que ese dato es el que se va a obtener.

La hora de análisis se puede realizar en momentos en los que no se encuentre la presencia de luz solar, esto para fines de predicción de las primeras horas del día o analizar de forma continua la presencia de nubosidad

2. Se convierte la imagen a escala de grises:
El objetivo de convertir la imagen a escala de grises es estandarizar el análisis de los datos, puesto que a pesar de que la imagen pareciera no realizar un cambio

Capítulo 5. Pruebas y resultados de predicción

importante, este es significativo puesto que la imagen descargada siempre se encuentra de tipo RGB y dificulta el análisis.

3. Se extrae el valor del pixel en cada cuadrante.
En general la imagen en el tipo de software que se analiza divide la el cuadrante en diversos pixeles, los cuales tienen el mismo valor en cada sección del cuadrante de análisis, por ello, se toma uno de los pixeles en cada sección y almacenan en una matriz para su siguiente análisis.

Para una mejor comprensión de la imagen adquirida y de los datos extraídos es importante mencionar que las tonalidades más claras en la imagen representan el vapor de agua, es decir, la presencia de nubosidad que hay en la zona

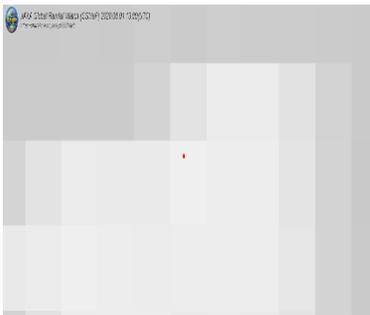


Figura 36. Imagen descargada

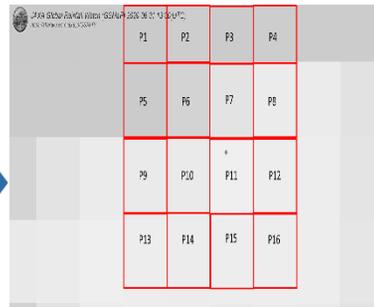


Figura 37. Imagen es escala de grises

08:00			
Pixel 1	Pixel 2	Pixel 3	Pixel 4
52	52	50	50
Pixel 5	Pixel 6	Pixel 7	Pixel 8
47	39	23	14
Pixel 9	Pixel 10	Pixel 11	Pixel 12
14	14	14	13
Pixel 13	Pixel 14	Pixel 15	Pixel 16
13	12	13	13

Figura 38. Extracción de datos

Finalmente, este mismo procedimiento se aplicó a 15 horas por los 30 días del mes de junio del año 2020, es decir, $[16 \times 15] \rightarrow 1$ día, $[16 \times 450] \rightarrow 30$ días y con esto obtener una base de datos la cual proporcionará información a la red neuronal.

5.5. Diseño de RNA de predicción

Para realizar la predicción de nubosidad se construyó una red neuronal tipo feed-forward, con aprendizaje back propagation. Una vez obtenida la base la red neuronal se entrenó concatenando los datos de los 16 píxeles de cada hora en secciones de 4 horas y recorriendo en cada renglón la hora siguiente, es decir, se vectorizaron las matrices de píxeles $P_n \in \mathbb{R}^{V \times 4}$ hacia vectores $V \in \mathbb{R}^{16}$ para cada instante se muestran 16 píxeles en cada hora, en secciones de 4 horas y recorriendo en cada renglón la hora siguiente obteniendo una matriz de entrada (int) de $[192 \times 16]$, en la figura siguiente se muestra un esquema representando las predicciones en cada iteración:

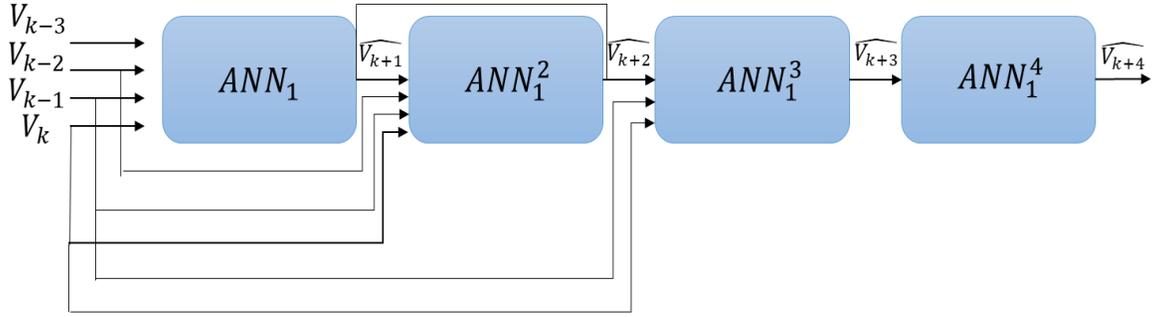


Figura 39. Esquema de predicción.

$$V = [v_{k-3}; v_{k-2}; v_{k-1}; v_k] \quad (51)$$

$$v_i \in \mathbb{R}^{16} \quad (52)$$

Para después en el target entrenar con los datos a predecir, haciendo una matriz de 11x16 siendo que con los datos de las primeras 4 horas. se pretende obtener el valor de los pixeles para las siguientes 12 horas, el diagrama de la matriz es el que se muestra en la figura.

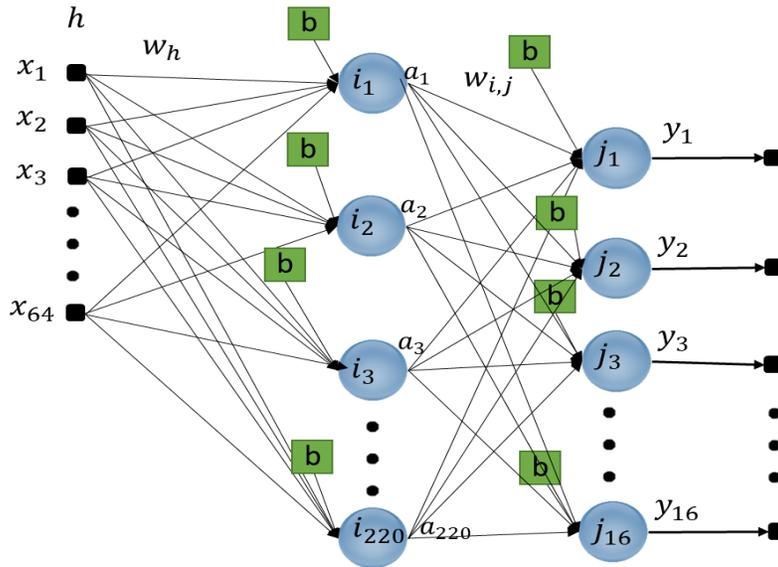


Figura 40. Red neuronal 1

Numero de capas: 2.

Numero de neuronas en la primera capa: 220.

Numero de neuronas en la segunda capa; 16.

Primera capa

$f_1 = \text{Tangente sigmoide}$

$$a_i = f_1 \left(\sum_{h=1}^{220} x_h w_{h,i} + b \right) \quad (53)$$

$$w_{h,i} = [w_{1,1}, \dots, w_{64,220}] \rightarrow 14080 \text{ pesos}$$

$$w_{i,j} = [w_{1,1}, \dots, w_{220,16}] \rightarrow 3520 \text{ pesos}$$

$f_1 = \text{Tangente sigmoide}$

$$a_1 = f_1(x_1w_{1,1} + x_2w_{2,1} + x_3w_{3,1} + \dots + x_{64}w_{64,1} + b) \quad (54)$$

$$a_2 = f_1(x_1w_{1,2} + x_2w_{2,2} + x_3w_{3,2} + \dots + x_{64}w_{64,2} + b) \quad (55)$$

$$a_3 = f_1(x_1w_{1,3} + x_2w_{2,3} + x_3w_{3,3} + \dots + x_{64}w_{64,3} + b) \quad (56)$$

⋮

$$a_{23} = f_1(x_1w_{1,23} + x_2w_{2,23} + x_3w_{3,23} + \dots + x_{64}w_{64,220} + b) \quad (57)$$

Segunda capa

$f_2 = \text{Lineal}$

$$y_j = f_2\left(\sum_{i=1}^{16} w_{i,j}a_i + b\right) \quad (58)$$

$f_2 = \text{Lineal}$

$$y_1 = f_2(a_1w_{1,1} + a_2w_{2,1} + a_3w_{3,1} + \dots + a_{220}w_{220,1} + b) \quad (59)$$

$$y_2 = f_2(a_1w_{1,2} + a_2w_{2,2} + a_3w_{3,2} + \dots + a_{220}w_{220,2} + b) \quad (60)$$

$$y_3 = f_2(a_1w_{1,3} + a_2w_{2,3} + a_3w_{3,3} + \dots + a_{220}w_{220,3} + b) \quad (61)$$

⋮

$$y_{16} = f_2(a_1w_{1,16} + a_2w_{2,16} + a_3w_{3,16} + \dots + a_{220}w_{220,16} + b) \quad (62)$$

Donde:

x_h = Datos de entrada

w_h = Peso sináptico

b = Bias

i = Neurona de la primera capa oculta

f = Función de activación

j = Neuronas de la segunda capa oculta

y = Salida de la red

5.6. Aplicación del método de predicción de irradiación

Una vez ya explicado el método de predicción de nubosidad, la obtención de irradiación solar en superficies horizontales y con estos datos corregirlos para obtener la irradiación solar global en una superficie inclinada, a continuación, se presentarán simulaciones y de este

Capítulo 5. Pruebas y resultados de predicción

proceso comparando los datos obtenidos con datos reales para visualizar la eficiencia de este método y posteriormente analizarlos en los siguientes capítulos.

5.7 Predicción de niveles de nubosidad

Para obtener los niveles de nubosidad es necesario primero realizar un banco de datos de los cuales se compone de la siguiente manera:

1. Se seleccionó como cuadrante de análisis alrededor del Instituto Mexicano de Tecnología del Agua (IMTA), esto porque de ahí fueron tomadas las muestras de irradiación solar.
2. Se extrajeron se extrajeron 192 imágenes satelitales obtenidas de Global Satellite Mapping of Precipitation (GSMaP) proporcionando 192 horas de datos continuos de nubosidad.
3. De las imágenes obtenidas se aplicó un tratamiento en escala de grises para obtener los niveles de nubosidad y posteriormente concatenar estos datos en una matriz de [192x16] compuesta de 192 horas de análisis y 16 datos extraído.
4. Una vez obtenido el banco de datos, se entrena la red neuronal y se aplican las predicciones, para analizar las predicciones se realizaron de dos formas, la primera, obteniendo predicciones a un solo paso, es decir con los datos de entrada que corresponden a 4 horas del día de predecía la hora 5, posteriormente la 6 y así sucesivamente hasta la hora 9, obteniendo los siguientes resultados:

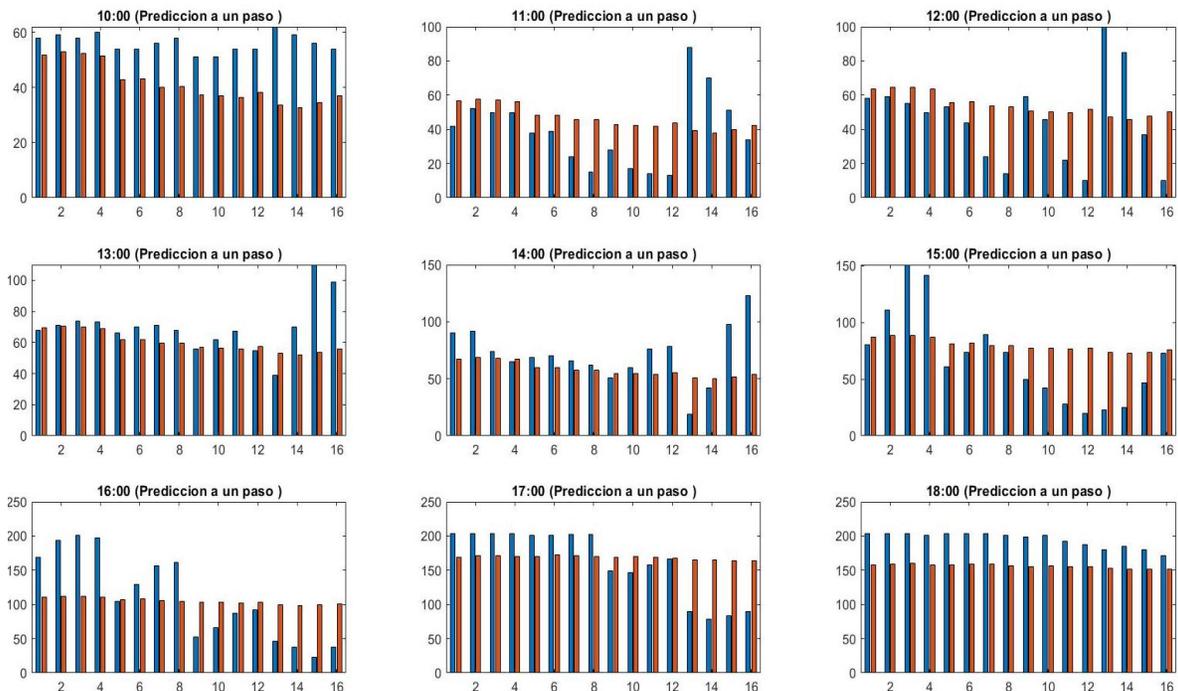


Figura 41. Predicciones a un paso (10 - 18 horas)

Capítulo 5. Pruebas y resultados de predicción

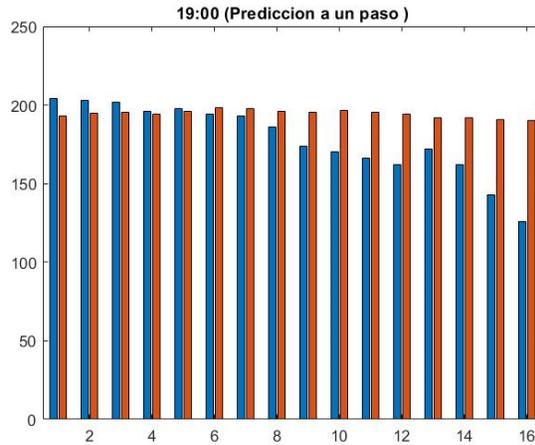


Figura 42. Predicción a un paso (19:00 horas)

En las gráficas podemos apreciar de color azul las barras que corresponden a los datos reales y de color rojo, las predicciones, lo que indica que al realizar la primera predicción los datos mantienen un bajo nivel de error.

5. Posteriormente se aplicó las mismas predicciones sin embargo estas se realizaron a múltiples pasos, es decir, con las primeras 4 horas se obtuvieron la hora 5, sin embargo, para la siguiente predicción se tomó la hora 5 como nuevo dato y eliminando el dato más antiguo, con esto obtuvimos los siguientes resultados:

6.

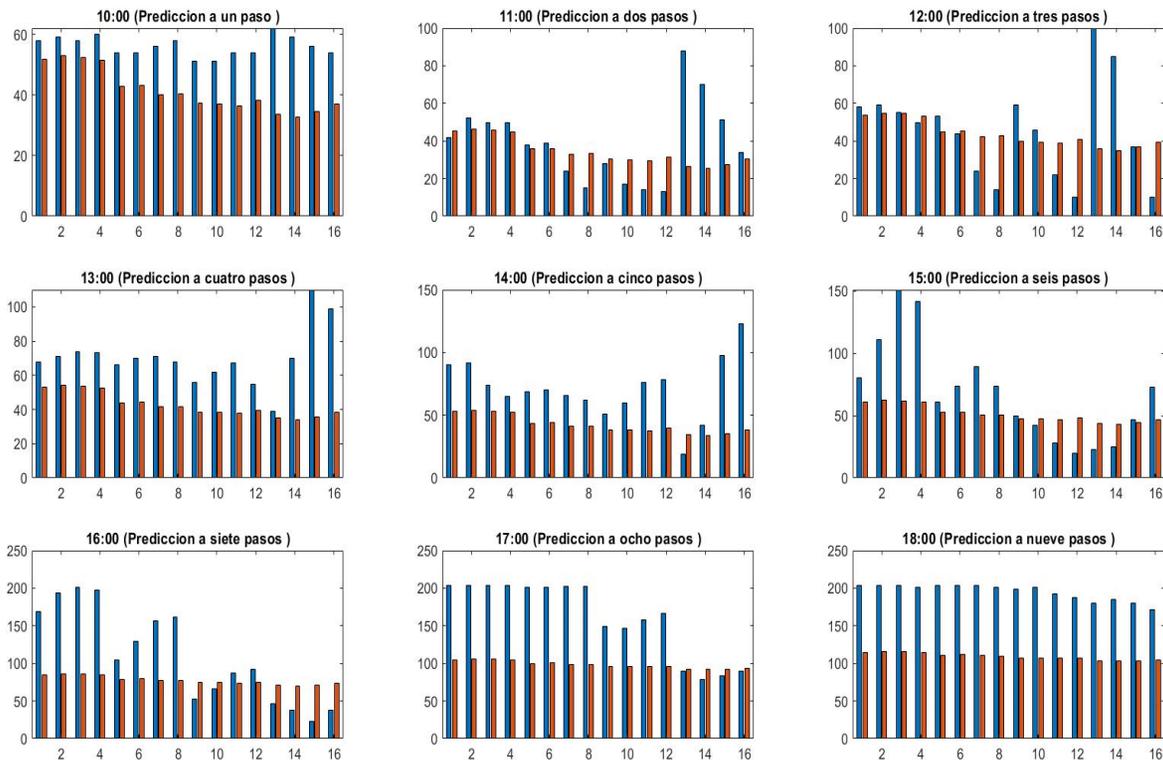


Figura 43. Predicciones a múltiples pasos (10 - 18 horas)

Capítulo 5. Pruebas y resultados de predicción

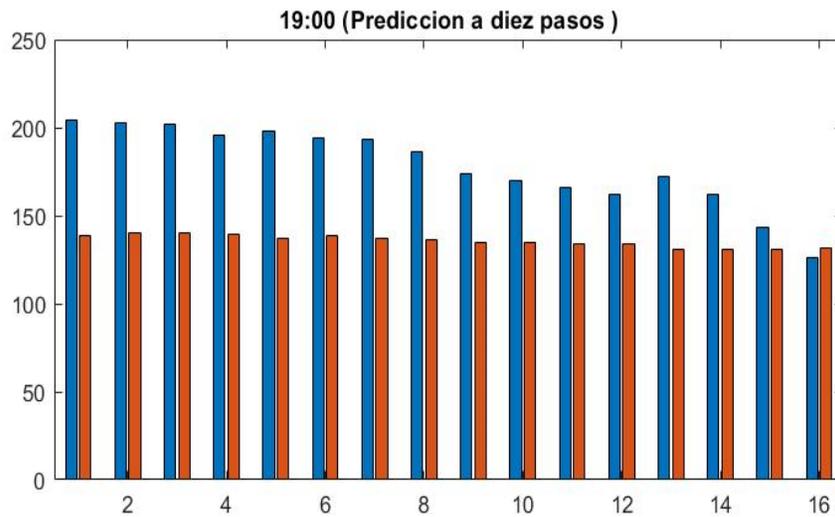


Figura 44. Predicción a múltiples pasos (19:00 horas).

De las gráficas de igual forma que las mencionadas anteriormente, las barras azules representan los niveles de nubosidad reales y las barras rojas los niveles de nubosidad predcidos, con esto y comparando con los resultados obtenidos a un paso podemos concretar que entre más lejano sea el paso de predicción el error se va incrementando, esto también atribuido al error almacenado desde las primeras predicciones y utilizado para las siguientes.

Para una visualización más clara también son reconstruidas las imágenes en escala de grises a partir de los niveles de nubosidad predcidos obteniendo las siguientes imágenes:

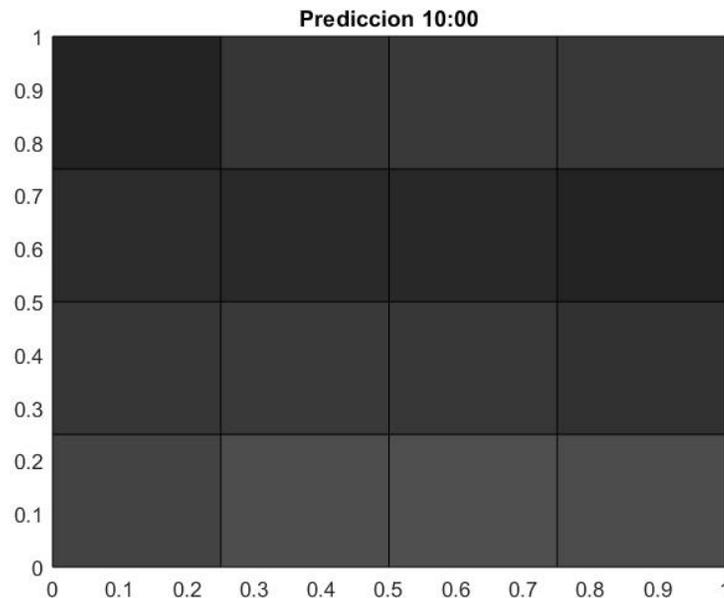


Figura 45. Predicción 10:00.

Capítulo 5. Pruebas y resultados de predicción

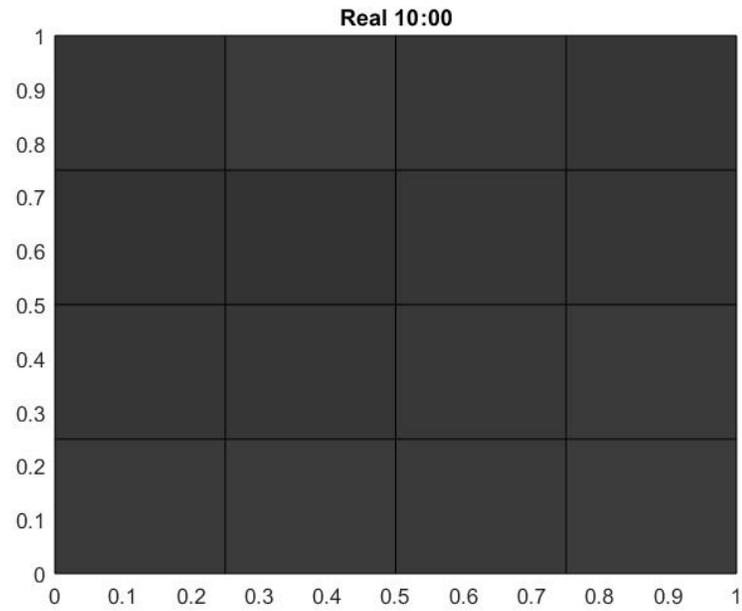


Figura 46. Dato real 10:00.

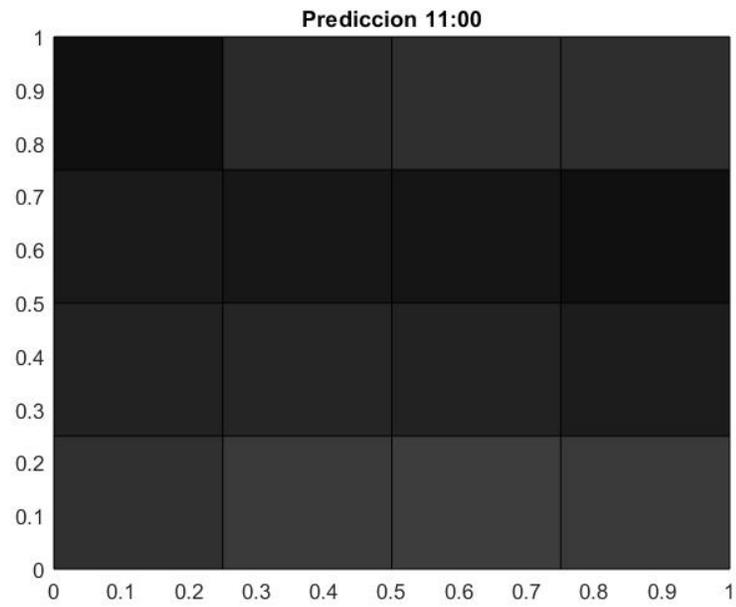


Figura 47. Predicción 11:00

Capítulo 5. Pruebas y resultados de predicción

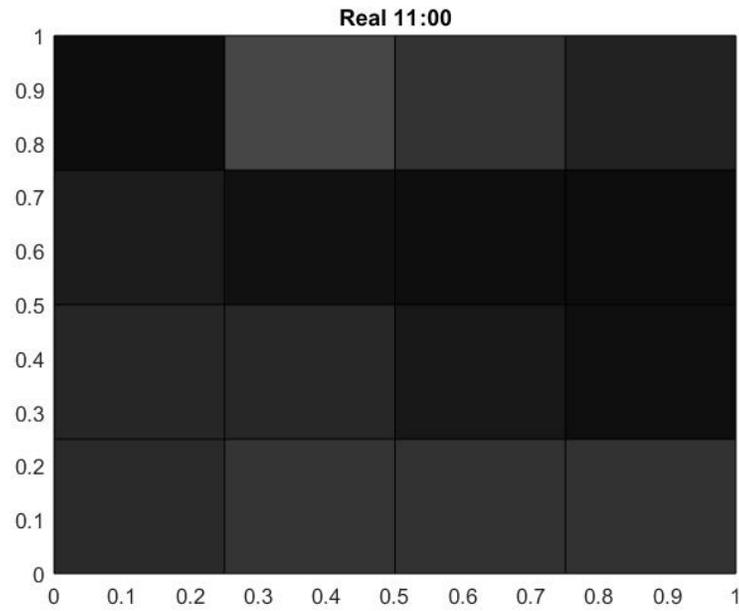


Figura 48. Dato real 11:00

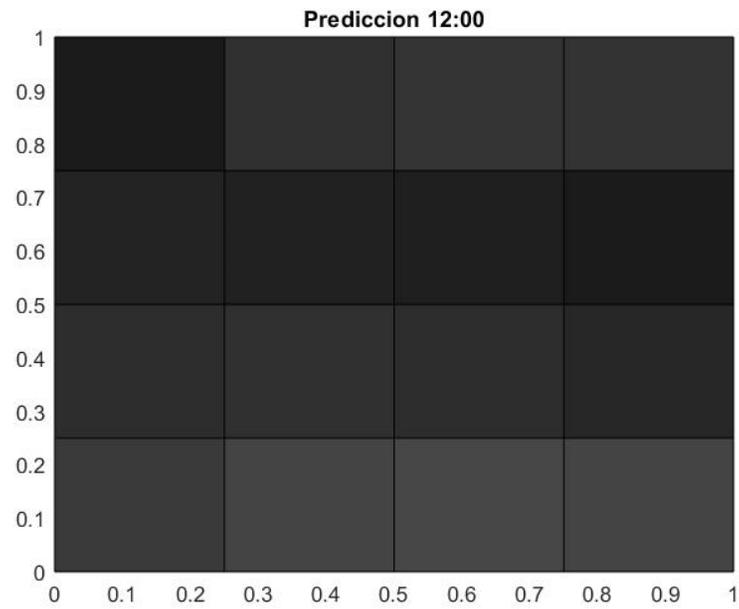


Figura 49. Predicción 12:00

Capítulo 5. Pruebas y resultados de predicción

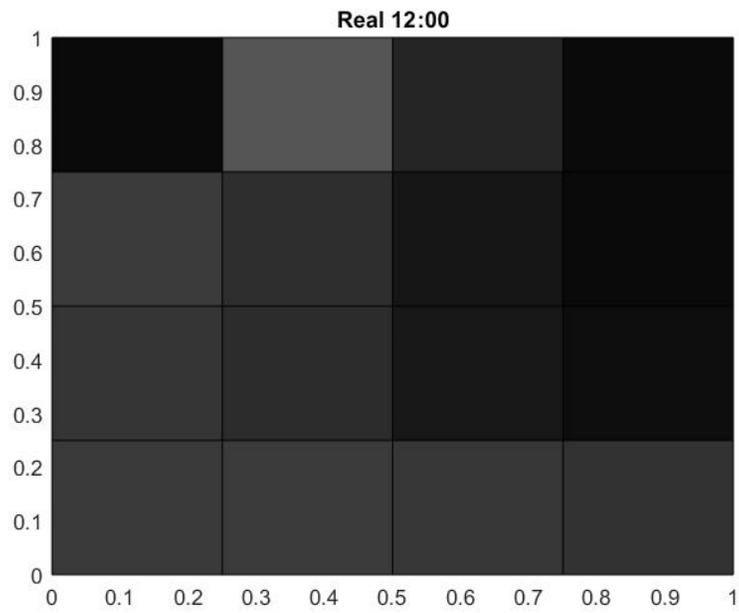


Figura 50. Dato real 12:00

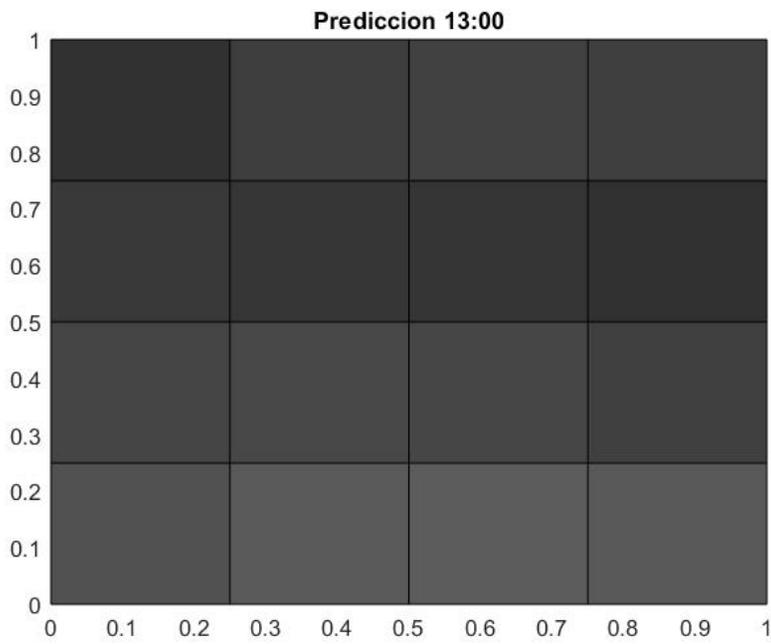


Figura 51. Predicción 13:00.

Capítulo 5. Pruebas y resultados de predicción

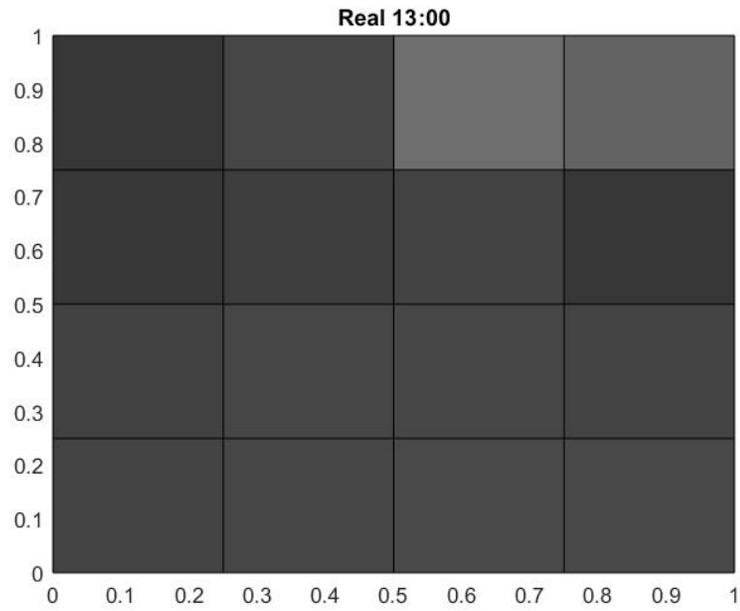


Figura 52. Dato real 13:00.

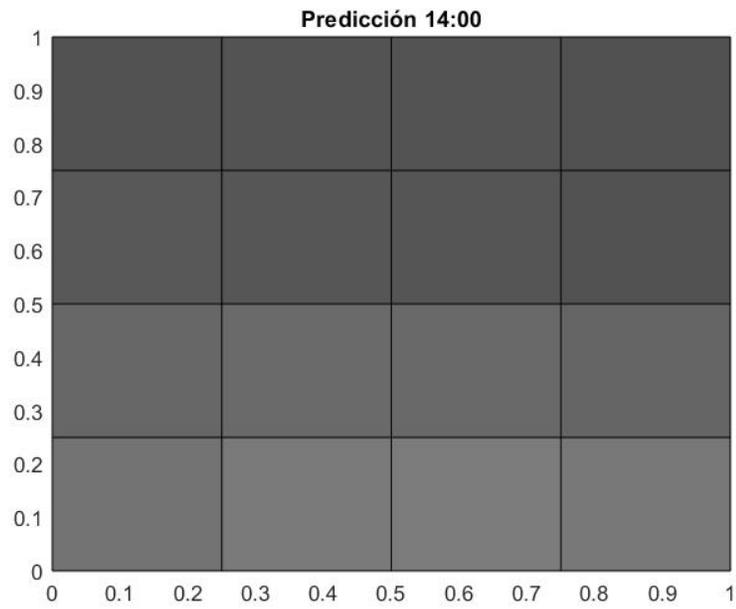


Figura 53. Predicción 14:00.

Capítulo 5. Pruebas y resultados de predicción

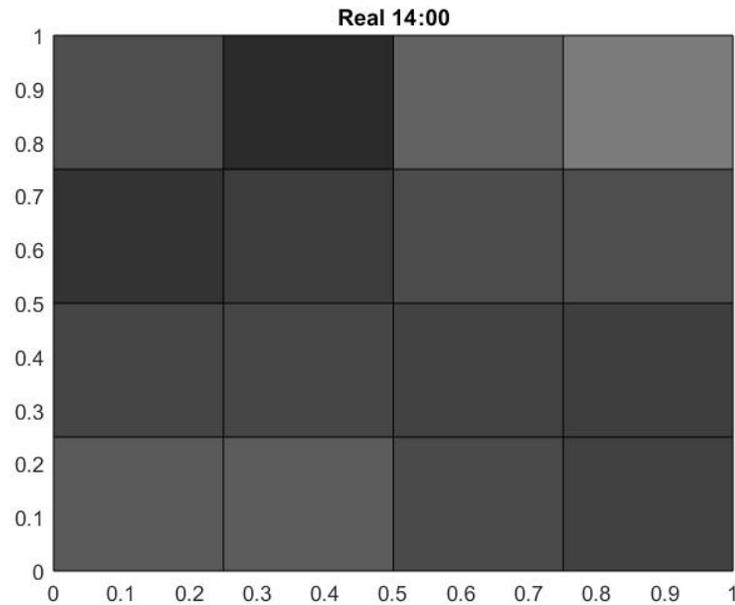


Figura 54. Dato real 14:00

De las imágenes anteriores es importante mencionar que las predicciones no buscan predecir exactamente todo el cuadrante de análisis, más bien se analiza este con el fin de proporcionar más información a la red neuronal, lo que nos lleva a que el cuadrante con más confiabilidad es el P11, que está señalado con un recuadro rojo. Esto es importante ya que, al realizar la corrección de nubosidad, el punto exacto de análisis sería esa sección del cuadrante.

La tabla representa los márgenes de error cuadrático medio porcentual obtenido entre la diferencia de los datos reales y los predecidos a múltiples pasos.

Tabla 7. Error Cuadrático Medio (ERM).

Horas	Red 1 (error%)
10	11.1859
11	15.4754
12	23.6643
13	18.2533
14	37.5732
15	59.1152
16	51.6563
17	30.2875
18	39.2703
19	23.4412
20	22.9183
Promedio total (%)	33.28409

5.8. Predicción teórica de irradiación solar

Esta predicción es obtenida a partir del modelo matemático de irradiación solar sobre una superficie horizontal el cual ya mencionamos anterior mente, todos estos datos son aplicados a las horas en las cuales se dese obtener la irradiación, para este caso fueron a partir del día 21 de junio del 2020, obteniendo los siguientes resultados:

En la Figura 55 se muestran de la irradiación solar sobre una superficie horizontal, de color azul la irradiación medida, esta de los datos adquiridos en por el IMTA y de color rojo la estimada por el modelo matemático teórico. En esta figura podemos apreciar cómo el modelo matemático dibuja una curva limpia, en la cual no tiene presencia de nubosidad, estimación que es notablemente errónea al no considerar este factor y por lo cual muestra la importancia de agregar la nubosidad para reducir este margen de error.

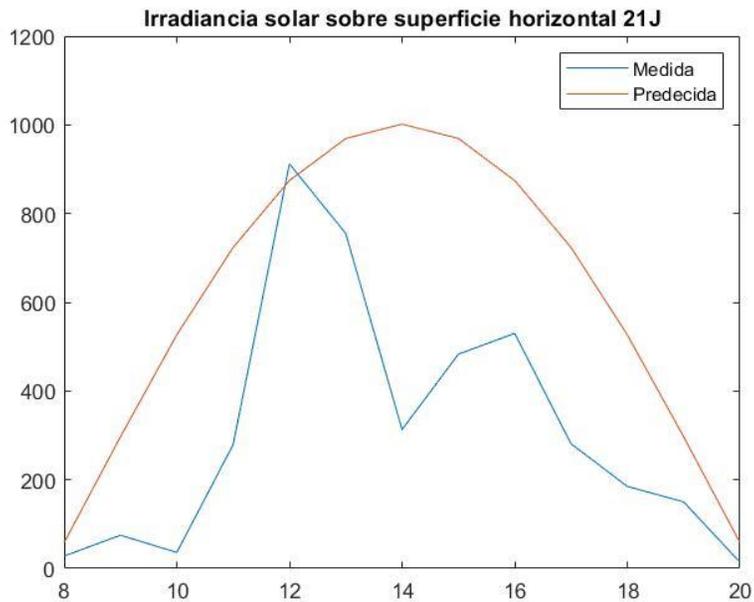


Figura 55. Irradiación 21 de junio.

En la figura 56 de igual forma que en la figura 57 se muestra la irradiación solar sobre una superficie horizontal, en la cual los datos utilizados para la gráfica pertenecen al día 22 de junio del 2020, día el cual la nubosidad presente en el día no afectó de manera abrupta por lo que se puede apreciar en las mediciones de irradiación una curva que a pesar de no tener cambios drásticos es aun notable la intervención de nubosidad puesto que después de las 14 horas se observa una disminución en la intensidad, lo que indicaría presencia de nubes.

Capítulo 5. Pruebas y resultados de predicción

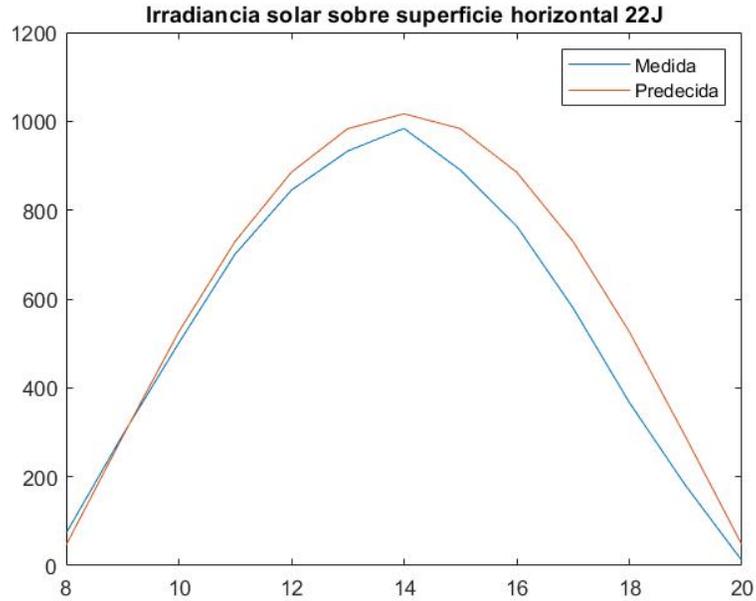


Figura 56. Irradiación 22 de junio.

En la Figura 57 podemos observar como la irradiación solar se ve afectada drásticamente por la presencia de nubosidad, sin embargo, la presencia de esta, no afecta de forma lineal, ya que varían el tipo de nubes presentes en la zona, es decir, podemos mencionar la hora 16 y la 17 de la Figura 57, se observa como en la hora 16 el cúmulo nuboso presente en ese punto disminuye importantemente los niveles de irradiación, sin embargo, en la hora 18 también existe presencia de nubosidad, pero a diferencia de la hora 16 la nubosidad no afectó de la misma forma.

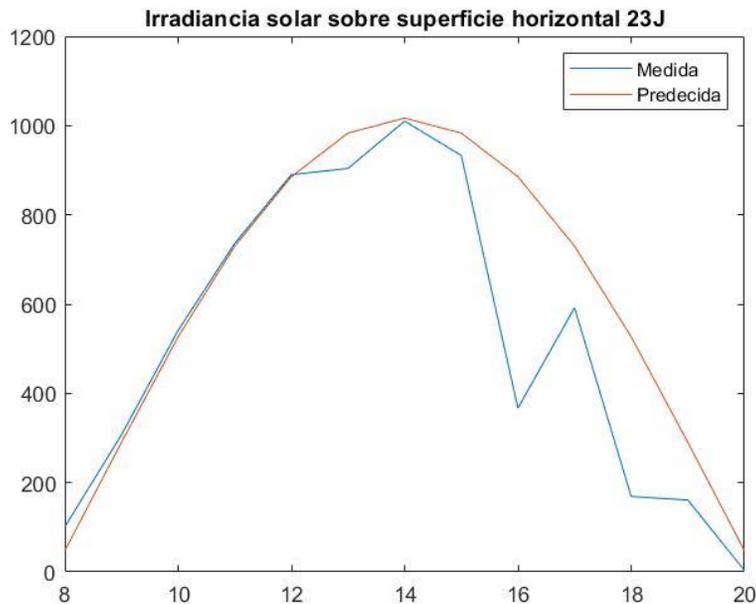


Figura 57. Irradiación 23 de junio.

Capítulo 5. Pruebas y resultados de predicción

En la Figura 58 se puede observar menos dinámica en la irradiación solar sobre una superficie horizontal, esto porque en ese día la nubosidad no se hizo presente, se podría decir que los cúmulos de nubosidad no se presentaban de manera tan concentrada e inclusive con mucha menos presencia a en comparación con la Figura 57.

Otro dato resaltante en la Figura 58 es que la irradiación predecida teóricamente por el modelo matemático resulto considerablemente eficiente, es decir, en ciertas condiciones donde los días no presentan niveles de nubosidad, el modelo matemático precisa datos muy cercanos a los medidos.

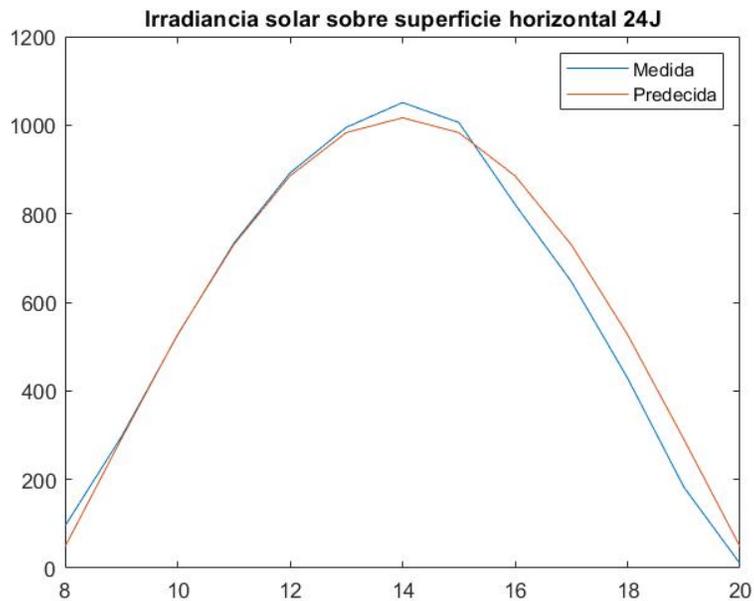


Figura 58. Irradiación 24 de junio.

En la Figura 59 se observa no solo el desfase que tienen, también el nivel máximo al que llegan estos datos. En la irradiación medida el dato máximo supera a la irradiación predecida teóricamente y no solo eso, los datos indican presencia de nubosidad con baja concentración lo cual provoca el desfase que se visualiza.

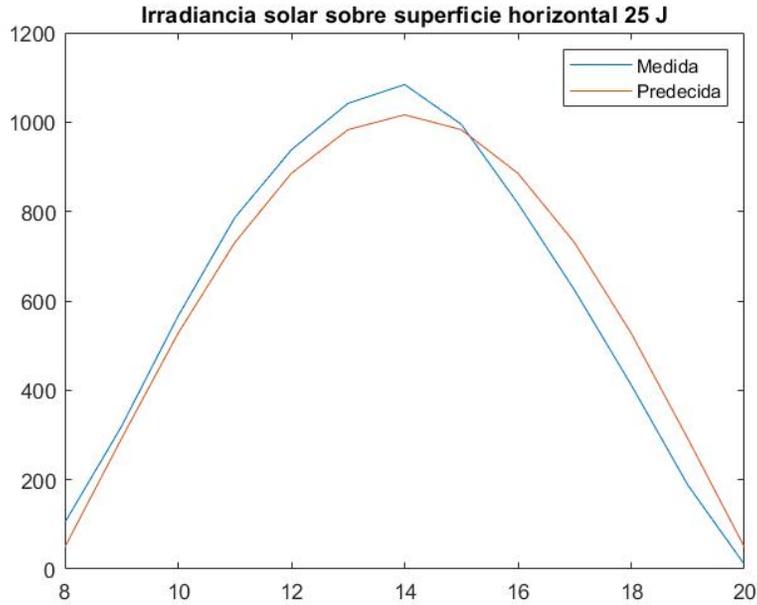


Figura 59. Irradiación 25 de junio.

En la Figura 60 una diferencia notoria, en la cual la irradiación solar medida y la predecida teóricamente presentan grandes diferencias entre ellas, esto por los altos niveles de nubosidad presentes en ese día en específico, con lo que podemos asumir que aun cuando la irradiación solar existente en ese día pudiese ser alta, la intervención de la nubosidad afecta considerablemente y la predicción teórica, que en días soleados proporciona datos eficientes, en días con niveles de alta nubosidad afecta importantemente y deja de ser eficiente en las predicciones.

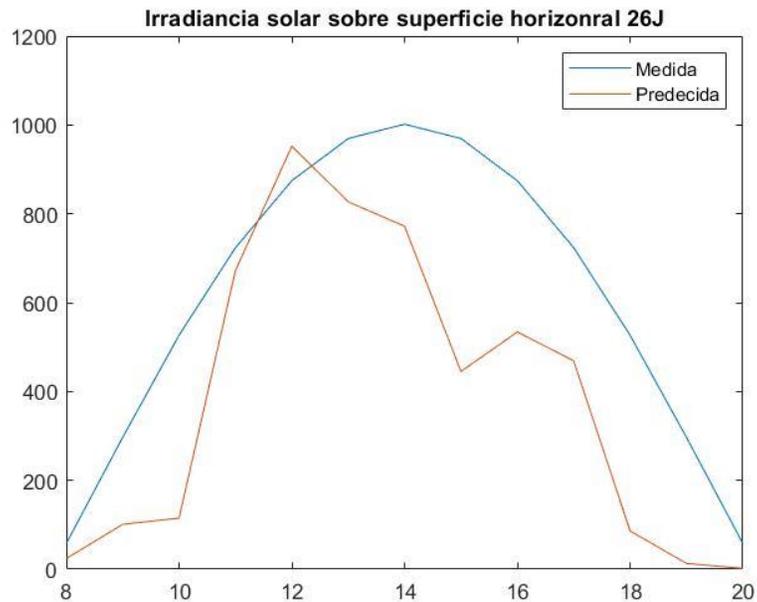


Figura 60. Irradiación 26 de junio.

En conclusión, con respecto las imágenes anteriores podemos observar algunos ejemplos con respecto al cálculo teórico de nubosidad, con el cual se realiza la estimación de irradiación solar sobre una superficie inclina. En la gráfica se compara en cada uno de los días los datos medidos contra los datos calculados a lo que podemos concretar lo siguiente:

- El cálculo teórico no difiere en gran nivel con los datos medibles, sin embargo, esto solo es válido si no existe mucha presencia de nubosidad.
- Es necesario agregar el método de corrección de nubosidad para obtener precisión en las predicciones con presencia de nubosidad.
- Continuar con el cálculo de irradiación solar sobre una superficie inclinada, se aplica un modelo el cual depende de valores como los que se muestran en las gráficas, por lo que podemos suponer que con los niveles correctos de nubosidad se obtienen predicciones adecuadas para el estudio.

5.10. Red neuronal artificial 2 (ANN2)

Como se menciona en la sección 3.4 es necesario obtener la irradiación solar sobre una superficie inclinada, la cual es obtenida a partir de los datos de irradiación solar sobre una superficie horizontal y los niveles de nubosidad proporcionados por ANN1.

En la Figura 61 y 62 la comparación y los resultados de la corrección realizada con respecto a los datos obtenidos \widehat{VP}_x e \widehat{I}_H . En la figura 61 observamos que los resultados son favorables, ya que, a pesar de no realizar una corrección perfecta, la red neuronal logra corregir varios puntos en los que asemejan el comportamiento de los niveles de irradiación en presencia de nubosidad, diferencia que no se obtiene con el método teórico.

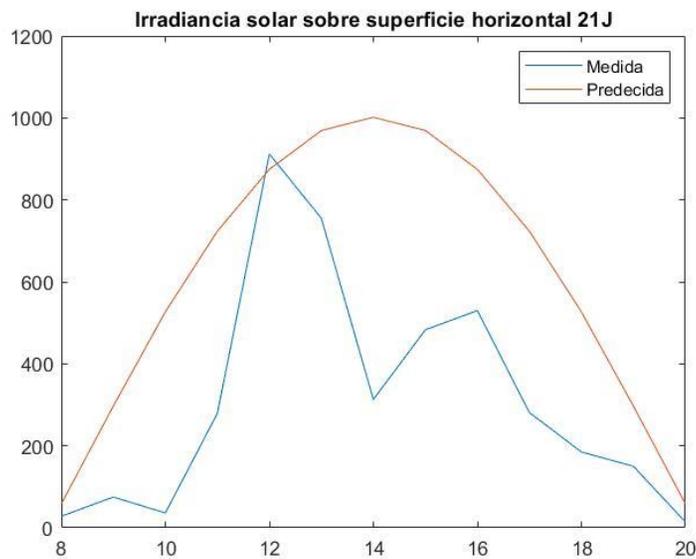


Figura 61. Corrección de irradiación solar.

Con respecto a los datos obtenidos en la Figura 62 podemos concluir lo siguiente:

- Existe una notoria mejora en la predicción de irradiación horizontal al intentar predecir días con presencia de altos niveles de nubosidad.
- Las predicciones, aunque no son perfectas, presentan resultados favorables, puesto que no solo en ciertos puntos logra empatar con los datos medidos, también asemeja su comportamiento.

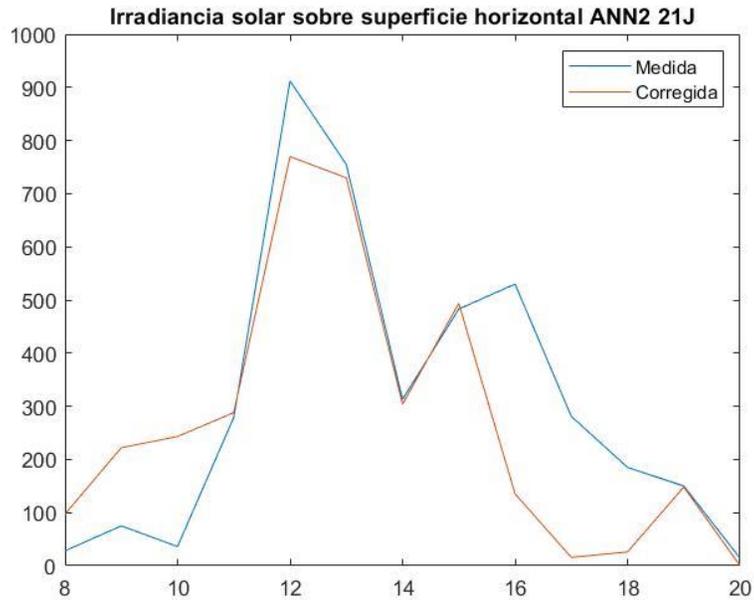


Figura 62. Predicción de irradiación solar.

5.11. Corrección y estimación de irradiación solar

Para realizar la corrección de la irradiación solar predecida e introducir los niveles de nubosidad se hizo uso de una red neuronal artificial, la cual, como datos de entrada se tienen los niveles de nubosidad y los niveles teóricos de irradiación, datos que fueron entrenados con datos reales extraídos de la red exactamente del Instituto Mexicano de Tecnología del Agua (IMTA), que podemos ver en la imagen través del portal de la Comisión Nacional del Agua (CONAGUA) se obtuvieron los datos hora a hora de los días analizados.

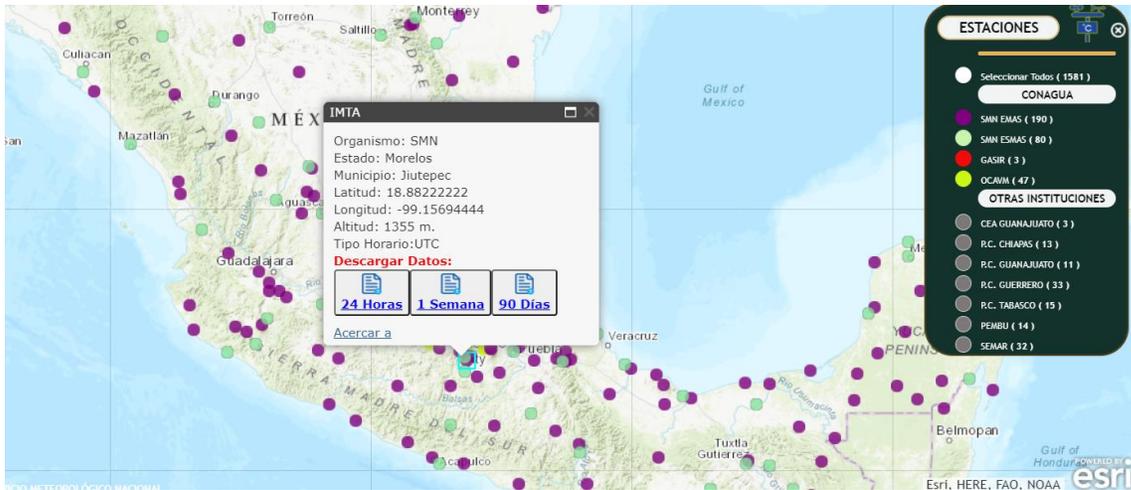


Figura 63. Punto de extracción de datos.

De los datos obtenidos anteriormente hasta esta sección se tiene obtenido el nivel de irradiación solar sobre una superficie horizontal real (I_H), en la Figura 63 se muestra el punto en el que nos encontramos con respecto al método que plantea esta tesis.

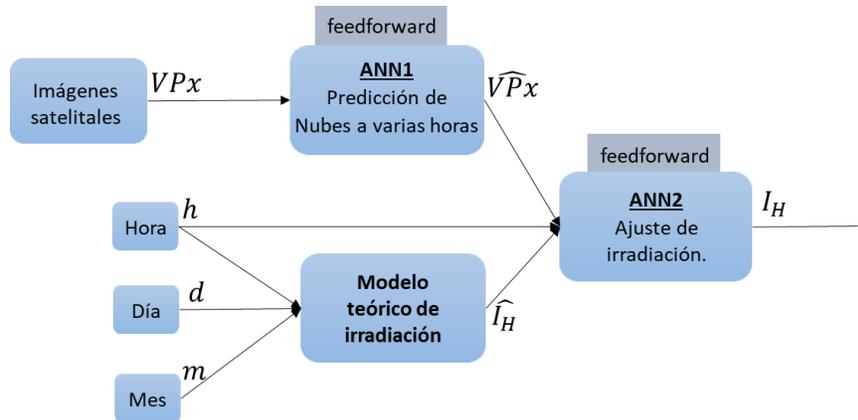


Figura 64. Esquema de irradiación solar horizontal.

5.12. Diseño de RNA para corrección

La red neuronal artificial 2 (ANN2) es la encargada de realizar la corrección que existe entre en el cálculo teórico de la irradiación solar global sobre una superficie horizontal, puesto que el modelo no contempla los cambios provocados por los cúmulos de nubosidad, esta red busca integrar ese dato indispensable, influyendo directamente sobre el cálculo matemático de I_H .

Para obtener la irradiación solar global horizontal real (I_H) es necesario ingresar en como datos de entrada los 16 niveles de pixel obtenidos de ANN1, los datos de irradiación solar

horizontal calculada del modelo teórico de irradiación solar global horizontal (I_H) y la hora local (h) del día en cuestión, todos los datos concatenados para después ser procesados en la red neuronal 2. Cabe mencionar que ANN2 no solo realiza la corrección de I_H , también al realizar la corrección utilizando (V_{Px}) se obtiene una estimación de (\hat{I}_H), para las horas siguientes.

Datos de entrada:

1. Irradiación solar horizontal calculada del modelo teórico de irradiación solar global horizontal (I_H).
2. Valor de pixel precedido (V_{Px}).
3. Hora local (h).

Estructura de ANN

1. Numero de capas 2.
2. Numero de neuronas en la primera capa: 5.
3. Numero de neuronas en la segunda capa 1.

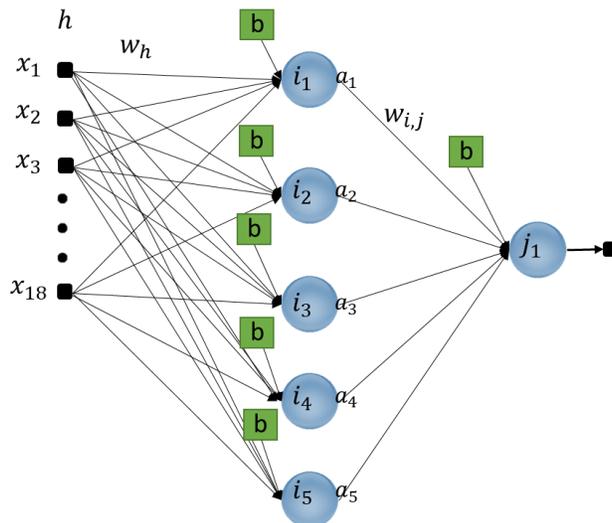


Figura 65. Red neuronal 2.

$$w_{h,i} = [w_{1,1}, \dots, w_{18,5}] \rightarrow 90 \text{ pesos}$$

$$w_{i,j} = [w_{1,1}, \dots, w_{5,1}] \rightarrow 5 \text{ pesos}$$

Capa 1: Capa oculta.

$$f_1 = \text{Tangente sigmoide}$$

$$a_i = f_1 \left(\sum_{h=1}^{18} x_h w_{h,i} + b \right) \tag{63}$$

Capa 2: Capa de salida.

$$f_2 = \text{Lineal}$$

$$a_j = f_2 \left(\sum_{i=1}^5 a_i w_{j,i} + b \right) \quad (64)$$

5.13. Predicción de irradiación sobre una superficie inclinada (G)

Como se menciona anteriormente no es suficiente analizar la generación de energía eléctrica producida por sistemas fotovoltaicos tomando como dato de entrada I_H , esto puesto que esta irradiación no representa completamente la captada por un sistema fotovoltaico, sin embargo, la irradiación sobre una superficie inclinada depende de I_H y los elementos que lo componen.

Una vez obtenida I_H podemos continuar con el método, regresando al modelo de irradiación sobre una superficie inclinada(G) obteniendo los siguientes resultados:

En la Figura 66 se puede observar que la irradiación solar inclinada se ve importantemente superada a la calculada, esto se debe a que los datos de irradiación inclinada obtenidos fueron corregidos con niveles de nubosidad, por lo cual, los niveles de irradiación solar disminuyeron considerablemente.

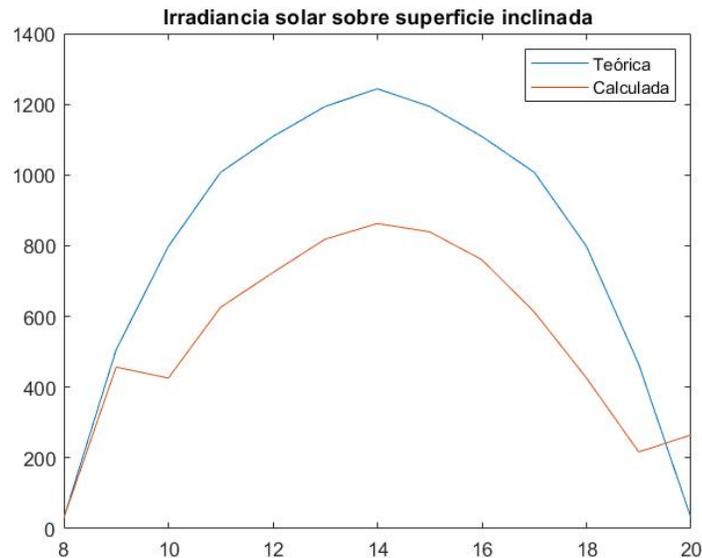


Figura 66. Irradiación solar inclinada predecida y teórica.

De los datos obtenidos con respecto a la irradiación solar sobre una superficie horizontal se puede resaltar lo siguiente:

- Los niveles de nubosidad no afectan directamente proporcional de forma horizontal que inclinada.
- La nubosidad genera variaciones en los niveles de irradiación.
- Gracias a la presencia de nubosidad disminuyen los niveles de irradiación.

5.14. Aplicación de Predicción en modelo de convertidor boost

Finamente se interconectaron el modelo de irradiación, el modelo del panel fotovoltaico y el modelo del convertidor utilizando los datos de la tabla obteniendo el voltaje de panel fotovoltaico (V_{pv}), la corriente del panel fotovoltaico (I_{pv}), el voltaje de salida del convertidor (V_{out}), y la corriente de salida del convertidor (I_{out}), expresados en las gráficas de la Figura 67.

Tabla 8. Tabla de irradiación global.

Fecha	Hora	Irradiación global inclinada G
21/6/2020	08:00	29.9
	09:00	504.4
	10:00	797.3
	11:00	1007.1
	12:00	1108.5
	13:00	1194
	14:00	1243.9
	15:00	1194
	16:00	1108.5
	17:00	1007.1
	18:00	797.3
	19:00	463.7
	20:00	29.9

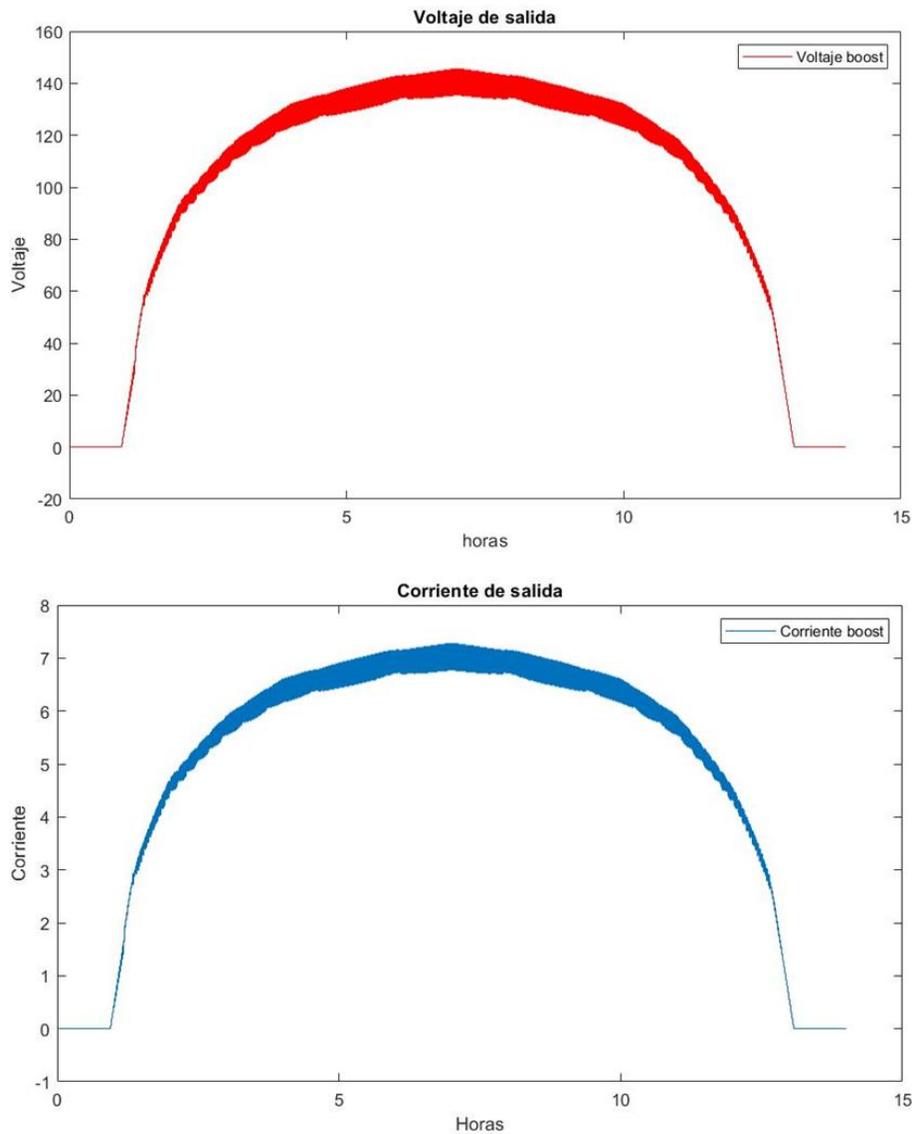


Figura 67. Simulación del panel fotovoltaico y el convertidor boost.

Observado las salidas del panel fotovoltaico y el convertidor con la entrada de la irradiación solar del modelo. Estas salidas se compararon con datos en la literatura y presentan un comportamiento muy similar, lo que indica que los sistemas están trabajando en conjunto de una forma apropiada y correcta.

5.15. Aplicación del método a diferentes estados de nubosidad

A continuación, se muestran los resultados obtenidos con el método antes mencionado, en el cual se buscaron abarcar días con niveles de nubosidad.

08/06/2020, día intermitente

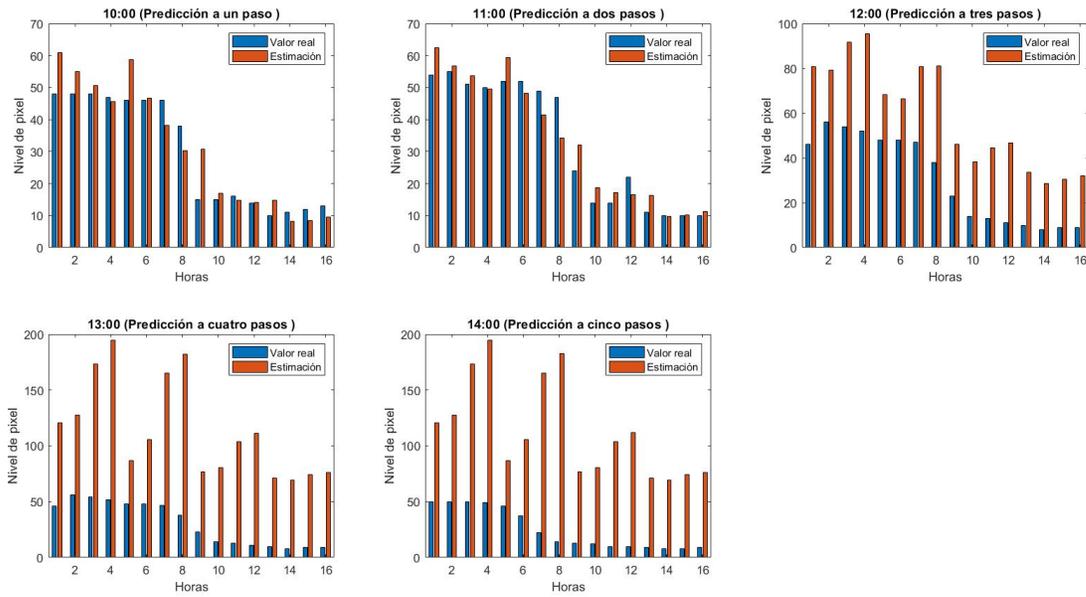


Figura 68. Predicción de nubosidad 08/06/2020

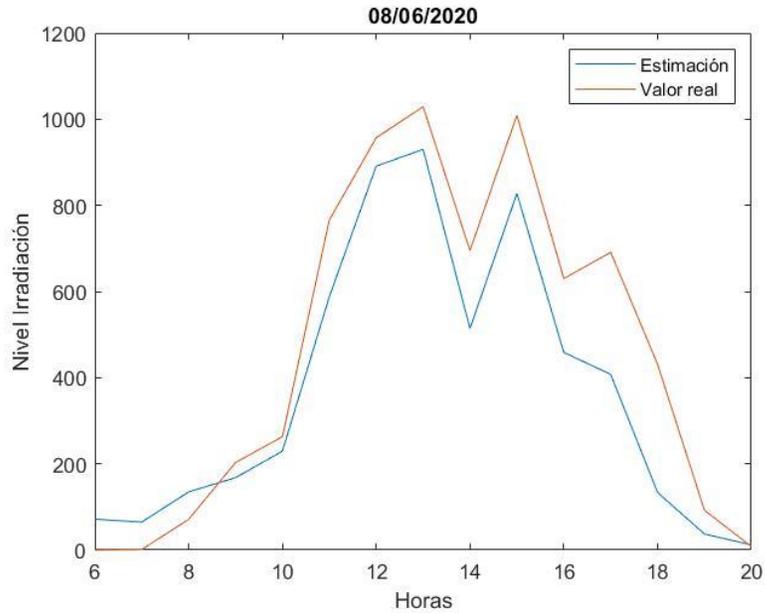


Figura 59. Comparación de IH

Capítulo 5. Pruebas y resultados de predicción

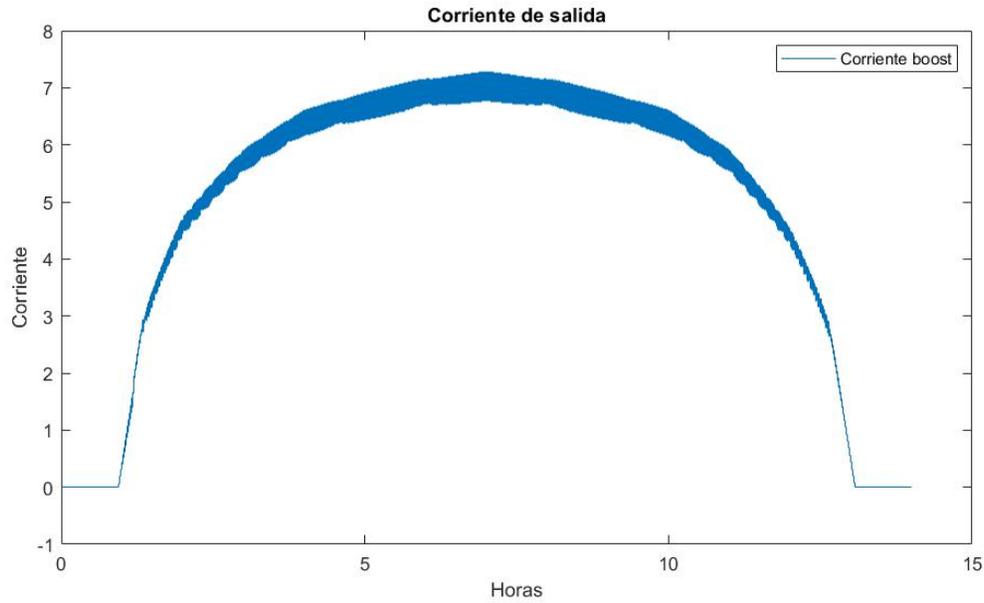


Figura 60. Corriente de salida 08/06/2020

06/06/2020, día nublado.

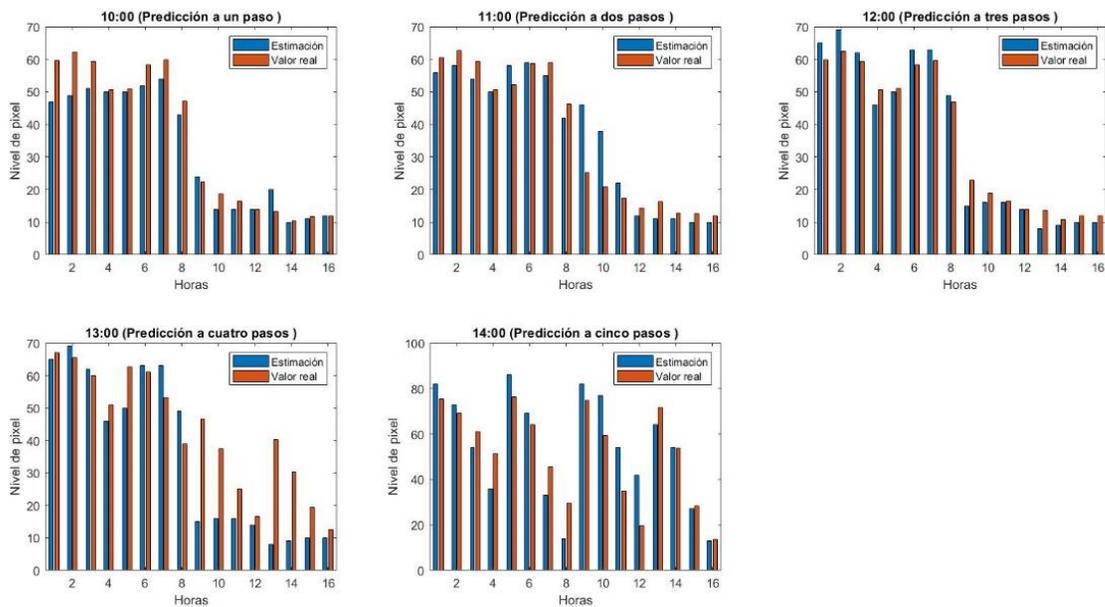


Figura 71. Predicción de nubosidad 06/06/2020

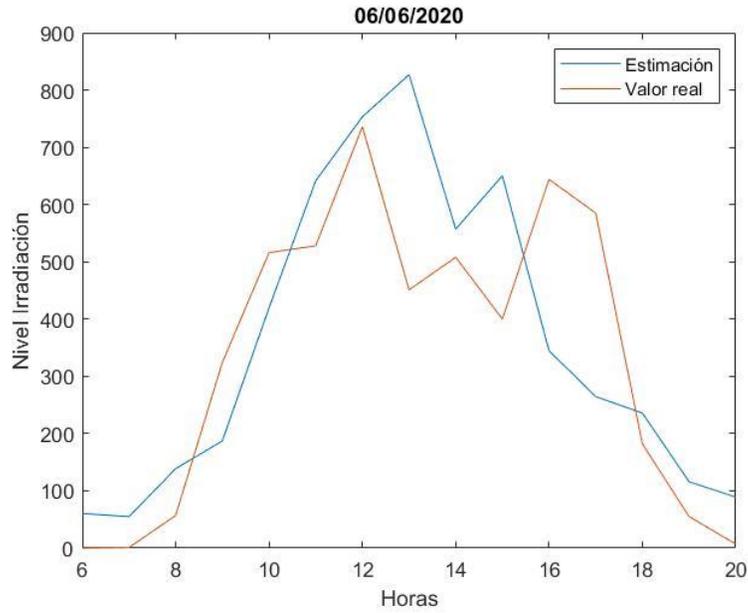


Figura 72. Comparación de IH

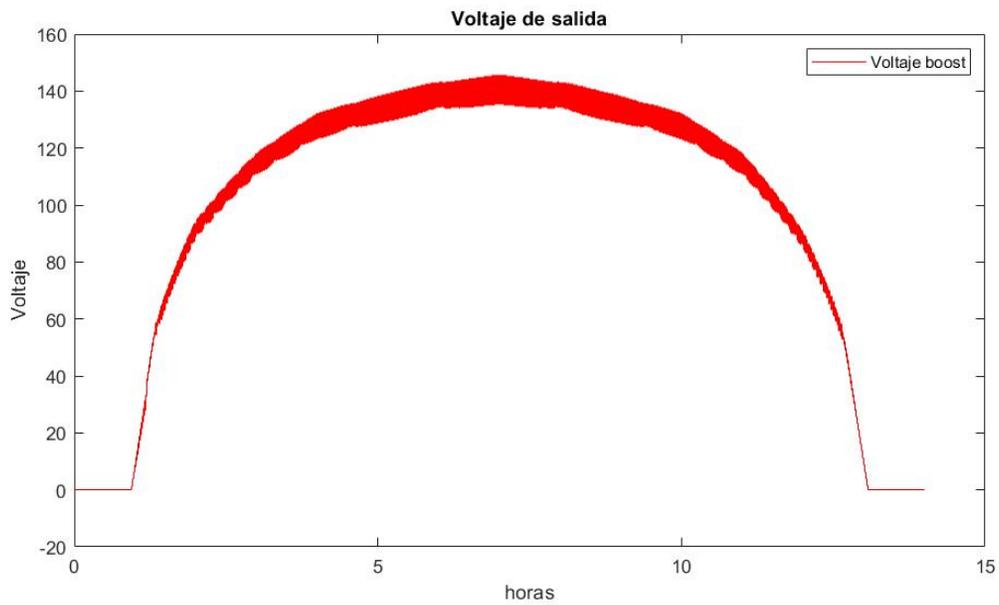


Figura 73. Voltaje de salida 08/06/2020

Conclusiones

6.1 Conclusiones

El objetivo de esta tesis es desarrollar una estrategia de predicción de la capacidad de generación de energía fotovoltaica a partir de imágenes satelitales, utilizando modelos matemáticos y técnicas de control para realizar predicciones en ciertos lapsos de tiempo y zonas determinadas.

En el presente documento uno de los objetos de estudio más importantes en el análisis de respuesta son los efectos que tienen los cúmulos de nubosidad sobre los sistemas fotovoltaicos interfiriendo con la radiación que captan estos sistemas por lo cual es importante tomar en cuenta los siguientes puntos:

- Al delimitar la zona de análisis para esta tesis se la zona de análisis es de un cuadrante de dimensión 4x4, sin embargo, se realizó previamente un análisis con una zona más reducida de 3x3, el cambio entre estos dos enfoques fue en los resultados ya que se observaron mejoras aportando más datos de análisis, aun cuando las muestras con las que se realizó el aprendizaje solo abarcan uno de los 16 píxeles analizados.
- La nubosidad a diferencia de la irradiación es posible analizarla las 24 horas, es decir, como se menciona la tesis, uno de los análisis realizados fue el entrenamiento de la red neuronal 1 con datos continuos de nubosidad, proporcionando mayor eficiencia en las predicciones.

Como podemos observar es posible obtener datos predictores de irradiación solar, las predicciones presentan cierto margen de error que como se puede apreciar en los niveles de ERMS conforme aumentan los pasos en la predicción también aumenta en cierto grado el error, es por esto, que se documentaron las predicciones en los primeros 5 pasos puesto que el error aún permanece relativamente pequeño para la predicción. Por otra parte, otro dato importante de resaltar es que el método híbrido entre las redes neuronales y los modelos.

Este modelo de predicción puede ser utilizado en conjunto con un modelo de panel fotovoltaico y convertidor.

6.2. Aportaciones

Las aportaciones de esta tesis son las siguientes:

- Desarrollo de un método de predicción introduciendo niveles de nubosidad.

- Diseño de un método híbrido en el cual se integran niveles de nubosidad con modelos matemáticos de irradiación solar obteniendo.
- Análisis de la influencia de la nubosidad presente sobre los niveles de irradiación solar.

6.3. Trabajos futuros

El uso de redes neuronales para esta tesis fue pieza clave, sin embargo, es importante resaltar que las redes neuronales utilizadas fueron de tipo feed forward, por lo cual, sería viable para futuras investigaciones comparar los resultados con otro tipo de red neuronal.

Esta tesis utilizó el modelo de Pérez para representar la irradiación solar sobre una superficie inclinada, por lo que tomando en cuenta los diversos modelos matemáticos de irradiación solar sería influyente en el proceso analizar un modelo que pueda reducir el proceso con el mismo margen de eficiencia.

En la tesis se analizó a grandes rasgos los niveles de nubosidad, sin embargo, los cúmulos de nubosidad se presenta en diversas clasificaciones por lo que para trabajos futuros sería un factor importante de analizar.

Bibliografía

A. E. Mejía, C. A. (2010). Conexión de un sistema fotovoltaico a la red eléctrica. *Scientia et Technica* Año XVI, 31. <https://doi.org/10.22517/23447214.1751>.

A. E. Mejía, M. H. (2011). Sistemas de almacenamiento de energía y su aplicación en energías renovables. *Scientia et Technica* Año XVII, 12.

A. K. Yadav, H. M. (2015). Ann based prediction of daily global solar radiation for photovoltaics applications. *IEEE indicon*.

B. Chen, P. L. (2020). Very-short-term power prediction for PV power plants using a simple and effective power RCC-LSTM model based on short term multivariate historical datasets. *electronics* <https://doi.org/10.3390/electronics9020289>.

C. Huang, A. B. (2016). Improvement in artificial neural network-based estimation of grid connected photovoltaic power output. *Renewable Energy* <https://doi.org/10.1016/j.renene.2016.06.043>.

C. Wan, J. Z. (2015). Photovoltaic and solar power forecasting for smart grid energy management. *CSEE journal of power and energy systems* <https://doi.org/10.17775/cseejpes.2015.00046>.

C. Yassine, M. M. (2019). Solar irradiance and temperature influence on the photovoltaic cell equivalent-circuit models. *Solar Energy* <https://doi.org/10.1016/j.solener.2019.07.005>.

E. I. Batzelis, G. A. (2018). A state-space representation of irradiance-driven dynamics in two-stage photovoltaic systems. *IEEE journal of photovoltaics*, Vol. 8 <https://doi.org/10.1109/JPHOTOV.2018.2839261>.

F. F. Valderrama, H. M. (2011). Análisis, simulación y control de un convertidor de potencia DC - DC tipo boost.

F. Serttas, F. O. (2018). Short term solar power generation forecasting: A novel approach. *PVCon 2018 - International conference on photovoltaic science and technologies* <https://doi.org/10.1109/PVCon.2018.8523919>.

F. Zhu, Q. Y. (2019). Photovoltaic power generation prediction using data clustering and parameter optimization. *APPEEC* <https://doi.org/10.1109/APPEEC45492.2019.8994454>.

G. Graditi, S. F. (2016). Comparison of photovoltaic plant power production prediction methods using a large measured dataset. *Renewable Energy*. <https://doi.org/10.1016/j.renene.2016.01.027>

G. Y. Aguirre, J. A. (2014). Implementación de estrategias de MPPT para sistemas de generación fotovoltaicos en un convertidor boost CC-CC. IEEE biennial congress of argentina, 1-6 <https://doi.org/10.1109/ARGENCON.2014.6868519>.

Gurney, K. (2004). An introduction to neural networks. London and New York: Routledge.
J. Melgarejo L. Romero, I. O. (2015). Aplicaciones satelitales para la meteorología. Academia Politécnica Naval.

Lamigueiro, O. P. (Noviembre de 2020). Energía Solar Fotovoltaica. Obtenido de creativecommons: <https://oscarperpinan.github.io/esf/>

luque, A. (2011). Handbook of photovoltaic science and engineering. Madrid, España: Wiley.

M. Pierro, F. B. (2016). Multi-model ensemble for day ahead prediction of photovoltaic power generation. Solar Energy <https://doi.org/10.1016/j.solener.2016.04.040>.

N. Aoun, K. B. (2019). Seasonal performance comparison of four electrical models of monocrystalline PV module operating in a harsh environment. IEEE Journal of photovoltaics, vol. 9, No. 4 <https://doi.org/10.1109/JPHOTOV.2019.2917272>.

N. Boujelben, F. M. (2017). Design and comparison of quadratic boost and double cascade boost converters with boost converter. International multi-conference on systems, signals & devices (SSD) <https://doi.org/10.1109/SSD.2017.8167022>.

P. Bunme, A. S. (2020). Solar power estimation using GIS considering shadow effects for distribution system planning. IEE <https://doi.org/10.1109/EEEIC/ICPSEurope49358.2020.9160547>.

R. G. Coronel, J. S. (2017). Correlación entre imágenes satelitales de nubosidad y precipitación. researchgate.

S kumar, A. P. (2018). MATLAB-Based simulation to analyze the aftermath of partial shading on solar Cell. IEEE, 437.

S. A. M. Maleki, H. H. (2017). Estimation of hourly, daily and monthly global solar radiation on inclined surfaces: Models Re-Visited. energies, 1-28 <https://doi.org/10.3390/en10010134>.

S. K. Singh, A. H. (2015). Performance evaluation of MPPT using Boost converters for solar photovoltaic system. 2th IEEE International Conference Electronics, Energy, Environment, Communication, Computer, Control: (E3-C3), INDICON 2015 <https://doi.org/10.1109/INDICON.2015.7443516>.

S. M. Lurwan, N. M. (2014). Predicting power output of photovoltaic systems with solar radiation model. IEEE International conference power and energy <https://doi.org/10.1109/PECON.2014.7062461>.

- S. S. Manna, S. M. (2020). Implementation of perturb observe mppt technique using boost converter in PV system. International conference on computational intelligence for smart power system and sustainable energy, CISPSSE 2020 <https://doi.org/10.1109/CISPSSE49931.2020.9212203>.
- S. Singh, S. M. (2020). Implementation of perturb & Observe MPPT. IEEE International conference on computational Intelligence for Smart Power System and Sustainable Energy, 1-4.
- S. Y. Alsadi, Y. F. (2017). Estimation of solar irradiance on solar fields: an analytical approach and experimental results. IEEE Transactions on sustainable energy, 1-8.
- Selvakumar, R. M. (2017). Review on artificial neural network based solar radiation prediction. 2nd International Conference on Communication and Electronics Systems (ICCES) <https://doi.org/10.1109/CESYS.2017.8321285>.
- Suzuki, K. (2011). Artificial neural networks methodological advances and biomedical applications. inTech.
- T. Ushio, T. I. (21 de 6 de 2020). JAXA globalrain fall watch. Obtenido de The Global Satellite Mapping of Precipitation (GSMaP) project: <https://sharaku.eorc.jaxa.jp/GSMaP/>
- Vega-Carrillo, H. R.-D.-A. (2007). Artificial neural networks technology for neutron spectrometry and dosimetry. Radiation Protection Dosimetry.
- Y. Chaibia, A. A. (2019). Solar irradiance and temperature influence on the photovoltaic cell. ELSEVIER, 2-10 <https://doi.org/10.1016/j.solener.2019.07.005>.
- Z. Si, M. Y. (2020). Hybrid solar forecasting method using satellite visible images and modified convolutional neural networks. Conference Record - Industrial and Commercial Power Systems Technical Conference <https://doi.org/10.1109/ICPS48389.2020.9176798>.