



**UNIVERSIDAD AUTÓNOMA DEL CARMEN**  
**FACULTAD DE INGENIERÍA**

---



# **TESIS**

## **“MODELO PREDICTIVO INTELIGENTE PARA LA PRODUCCIÓN DE ENERGÍA ELÉCTRICA EN UN SISTEMA FOTOVOLTAICO”**

PARA OBTENER EL GRADO DE:

MAESTRO EN INGENIERÍA MECATRÓNICA

PRESENTA:

**FERNANDO ARELLANO VALMAÑA**

**CIUDAD DEL CARMEN, CAMPECHE, NOV. DE 2019**



**UNIVERSIDAD AUTÓNOMA DEL CARMEN**  
**FACULTAD DE INGENIERÍA**



# **TESIS**

## **“MODELO PREDICTIVO INTELIGENTE PARA LA PRODUCCIÓN DE ENERGÍA ELÉCTRICA EN UN SISTEMA FOTOVOLTAICO”**

PARA OBTENER EL GRADO DE:

MAESTRO EN INGENIERÍA MECATRÓNICA

PRESENTA:

**FERNANDO ARELLANO VALMAÑA**

DIRECTOR DE TESIS

**DR. JOSÉ ANTONIO RUZ HERNÁNDEZ**

CO-DIRECTOR DE TESIS

**DR. NUN PITALÚA DÍAZ**

**CIUDAD DEL CARMEN, CAMPECHE, NOV. 2019**

*Dedicado a  
mi familia.*

*Sólo los apasionados llevan a cabo  
obras verdaderamente fecundas y duraderas.*

# Dedicatoria

A mi familia quien siempre me ha apoyado en los momentos buenos y malos, en las situaciones que requerían de calma y tranquilidad para resolverse siendo difícil encontrarlo solo por mí.

# Agradecimientos

Agradezco a la Universidad Autónoma del Carmen por permitirme continuar con mis estudios de posgrado así como por sus atenciones hacia mi persona durante el transcurso del programa educativo. De igual manera agradezco al Dr. José Antonio Ruz Hernández por haber sido mi profesor y asesor, apoyándome siempre con su disponibilidad y confianza en la realización de este trabajo. Agradezco a la Universidad de Sonora por aceptarme durante mi estancia en Hermosillo y brindarme todo el apoyo que necesité para el cumplimiento de este documento. Así mismo agradezco al Dr. Nun Pitalúa Díaz por su apoyo constante e incanzable como mi co-director durante mi estancia siempre buscando la superación de un servidor así como mi bienestar físico y mental.

Agradezco al Dr. Marco Antonio Rodríguez Blanco por toda la ayuda y tiempo proporcionados durante el transcurso del posgrado como profesor y gestor para lograr concluir esta etapa de manera eficiente.

Agradezco al Dr. Youness El Hamzaoui y al Dr. Ramón García Hernández por el apoyo otorgado en su papel de revisores y en especial al Dr. Hussain Alazki como profesor y revisor por su tiempo, atención, comentarios y consejos siempre buscando la mejora continua tanto mia como de este trabajo.

Agradezco al Consejo Nacional de Ciencia y Tecnología por aceptarme como becario de posgrado y por la beca mixta o de movilidad, apoyos sin los cuales nunca hubiera logrado concluir semejante logro.

Agradezco a mis padres y mis hermanos quienes a lo largo de mi vida han estado siempre presentes y dispuestos a apoyarme en las decisiones fáciles y difíciles siempre buscando mi superación hacia una mejor calidad de vida, lo cual nunca hubiera logrado de no haberlos tenido a ellos como mi base y cimientos morales cada día de mi vida.

# Resumen

Este trabajo presenta la generación de un modelo predictivo inteligente, aplicando un ANFIS (Adaptive Neuro-Fuzzy Inference System) como método inteligente, para la producción de energía eléctrica en un sistema fotovoltaico. Para la creación del mismo es necesario un proceso de tres pasos: obtención de los datos de entrada y salida, la generación del modelo y su funcionalidad como predictor.

La primer parte del proceso es la más importante debido a que la característica principal de las redes neuronales es su posible aplicación sin conocerse el modelo matemático del sistema a trabajar. Dicho modelo es posible aproximarlos a través de los datos de entrada y salida del sistema. Mientras mayor sea la cantidad de datos y su correlación, mejor calidad tendrá la aproximación o modelo.

Una vez teniendo los datos se procede a encontrar el modelo que mejor represente el sistema a usar. Debido a que el modelo es una aproximación del sistema real, se busca la mejor versión aplicando varios métodos de aprendizaje para la red neuronal así como diferentes funciones de pertenencia o membresía en el sistema difuso para las variables tanto de entrada como de salida. La correcta elección de estas características llevará a encontrar un modelo que represente de manera fiel el comportamiento del sistema físico real aplicando datos de prueba o “datos frescos”.

Habiendo encontrado el modelo (más aproximado) por el método inteligente, el paso final es adecuarlo para que pueda trabajar independiente y recursivamente. De esta manera el modelo, como predictor, consiste en que por sí solo genere datos de salida en un tiempo a futuro determinado y sean lo más cercanos posible a los valores reales en dicho tiempo.

# Abstract

This work presents the creation of an intelligent predictive model, applying an ANFIS (Adaptive Neuro-Fuzzy Inference System) as intelligent technique, for the electrical energy production in a photovoltaic system. In order to create, a three steps process is necessary: input and output data gathering, model generation and its functionality as predictor.

The first part of the process is the most important because the main characteristic of neural networks is its application without knowing the mathematical model of the considered system. It is possible to approximate the model through the input and output data of the system. While greater the amount of data and its correlation among them, better the quality of the approximation.

Once all the data is gathered, it is proceeded to find a model that best represents the system considered. The best version of the model is looking for applying different learning methods for the neural network and several membership functions in the fuzzy system for the input and output variables. The correct choice of these characteristics will lead to find a model that best resembles the behavior of the real physical system applying test data or "fresh data".

Once the most approximated model has been found by the intelligent technique, the final step is to adequate it in order to work independently and recursively. By this, the model as predictor, consists in generating output data in a fixed forward time autonomously, been the closest possible to the real data at the same time.

# Índice general

Dedicatoria	II
Agradecimientos	III
Resumen	IV
Abstract	V
Índice general	VI
Índice de figuras	VIII
Índice de tablas	X
Lista de abreviaturas y símbolos	X
<b>1. Introducción</b>	<b>1</b>
1.1. Problemática . . . . .	1
1.2. Antecedentes . . . . .	2
1.3. Objetivos . . . . .	5
1.3.1. Objetivo general . . . . .	5
1.3.2. Objetivos específicos . . . . .	5
1.4. Aportación . . . . .	6
1.5. Organización de la tesis . . . . .	6
<b>2. Conceptos de un sistema fotovoltaico y su funcionalidad</b>	<b>7</b>
2.1. Constitución de un sistema fotovoltaico . . . . .	7
2.1.1. Panel solar . . . . .	7
2.1.2. Batería . . . . .	8
2.1.3. Regulador de carga . . . . .	8
2.1.4. Inversor . . . . .	9
2.2. Conclusiones del capítulo . . . . .	10
<b>3. Datos meteorológicos</b>	<b>11</b>
3.1. Estación meteorológica . . . . .	11
3.2. Piranómetro . . . . .	13
3.3. Conclusiones del capítulo . . . . .	14
<b>4. Sistemas inteligentes</b>	<b>15</b>
4.1. Red Neuronal Artificial . . . . .	15
4.1.1. Generalidades . . . . .	15
4.1.2. Parámetros y funciones de activación . . . . .	16
4.1.3. Entrenamiento . . . . .	18
4.2. Sistema Difuso . . . . .	19
4.2.1. Generalidades . . . . .	19
4.2.2. Sentencias difusas y funciones de membresía . . . . .	19
4.2.3. Proceso de inferencia difusa . . . . .	20
4.2.4. Tipos de sistemas difusos . . . . .	21
4.3. Red Adaptable basada en Sistemas de Inferencia Difusa . . . . .	23
4.3.1. Generalidades . . . . .	23
4.3.2. Descripción de un ANFIS . . . . .	23



4.3.3. Entrenamiento . . . . .	24
4.4. Conclusiones del capítulo . . . . .	26
<b>5. Generación del modelo predictivo inteligente</b>	<b>27</b>
5.1. Selección de las variables meteorológicas . . . . .	27
5.1.1. Correlación, recta de regresión y coeficiente de determinación . . . . .	27
5.1.2. Optimización por Gradiente Descendente . . . . .	30
5.1.3. Selección . . . . .	31
5.2. Modelo ANFIS . . . . .	32
5.2.1. Entrenamiento del sistema . . . . .	32
5.2.2. Resultados . . . . .	45
5.3. Conclusiones del capítulo . . . . .	49
<b>6. Validación</b>	<b>50</b>
6.1. Comparación contra métodos estadísticos . . . . .	50
6.2. Análisis de precisión . . . . .	52
6.3. Conclusiones del capítulo . . . . .	57
<b>7. Conclusiones y trabajos futuros</b>	<b>58</b>
7.1. Conclusiones . . . . .	58
7.2. Trabajos futuros . . . . .	58
<b>Bibliografía</b>	<b>59</b>
<b>A. Descarga de datos del Inversor GALVO 3.1-1</b>	<b>64</b>
A.1. Creación de un equipo virtual . . . . .	64
A.2. Descarga de datos en el sitio por LAN . . . . .	65
A.3. Visualización del inversor en línea . . . . .	69
A.3.1. Por conexión inalámbrica . . . . .	69
A.3.2. Por conexión LAN . . . . .	70
<b>B. Descarga de datos de la estación meteorológica VANTAGE PRO 2</b>	<b>72</b>
B.1. Descarga de datos y variables . . . . .	72
<b>C. Publicaciones</b>	<b>77</b>
C.1. Applied Sciences . . . . .	78
C.2. Energies . . . . .	79
C.3. Congreso Interdisciplinario de Energías Renovables, Mantenimiento Industrial, Mecatrónica e Informática . . . . .	80

# Índice de figuras

1.1. Total de recursos energéticos en la Tierra. . . . .	2
1.2. Predicción del uso de los recursos. . . . .	2
1.3. Atlas de la radiación solar en México. . . . .	3
1.4. Radiación global horizontal mundial. . . . .	4
2.1. Efecto fotovoltaico en una celda p-n. . . . .	8
2.2. Sistema fotovoltaico UNISON. . . . .	8
2.3. Inversor FRONIUS GALVO 3.1-1 . . . . .	9
3.1. Estación meteorológica VANTAGE PRO2 . . . . .	11
3.2. Esquema de funcionamiento de la estación VANTAGE PRO 2 . . . . .	13
3.3. Piranómetro. . . . .	14
4.1. Red adaptable . . . . .	16
4.2. Sistema de inferencia difusa . . . . .	21
4.3. Ejemplo de tres funciones de membresía de tipo trapezoidal. . . . .	21
4.4. Tipos de sistemas difusos. . . . .	22
4.5. Proceso de un sistema difuso Tipo 3. . . . .	23
4.6. Estructura de un ANFIS equivalente a un Tipo 3. . . . .	23
5.1. Diagramas de dispersión. (a) Radiación solar; (b) Temperatura; (c) Humedad; (d) Sensación térmica; (e) Punto de rocío; (f) Presión atmosférica; (g) Velocidad del viento; (h) Dirección del viento; (i) Hora del día . . . . .	29
5.2. Esquema de entrenamiento . . . . .	32
5.3. Esquema como predictor . . . . .	32
5.4. Arquitectura final para el entrenamiento del sistema neurodifuso. . . . .	34
5.5. Datos de entrenamiento. (a) Radiación solar; (b) Dirección del viento; (c) Humedad; (d) Presión atmosférica; (e) Temperatura; (f) Velocidad del viento; (g) Hora del día; (h) Potencia eléctrica. . . . .	35
5.6. Funciones de membresía del ANFIS 1 después del entrenamiento: (a) Radiación solar tipo triangular, (b) Dirección del viento en grados tipo triangular, (c) Humedad tipo trapezoidal. . . . .	36
5.7. Funciones de membresía del ANFIS 2 después del entrenamiento: (a) Presión atmosférica tipo triangular, (b) Temperatura tipo Gauss. . . . .	39
5.8. Funciones de membresía del ANFIS 3 después del entrenamiento: (a) Velocidad del viento tipo triangular, (b) Hora del día tipo triangular, (c) Potencia tipo Gauss. . . . .	40
5.9. Funciones de membresía del ANFIS 4 después del entrenamiento: (a) ANFIS 1 tipo Gauss, (b) ANFIS 2 tipo Gauss, (c) ANFIS 3 tipo Gauss. . . . .	43
5.10. Resultado del sistema neuro-difuso implementado. . . . .	46
5.11. Arreglo ANFIS con salida acotada. . . . .	46
5.12. Diagrama de flujo del acotamiento. . . . .	47
5.13. Resultado del sistema neuro-difuso implementado con acotamiento. . . . .	47
5.14. Arreglo ANFIS autorecursivo. . . . .	48
5.15. Resultado del sistema neuro-difuso implementado autorecursivo con acotamiento. . . . .	48
6.1. Resultados obtenidos usando los datos de entrenamiento. (a) Estimación por OGD contra datos reales; (b) Estimación por ANFIS contra datos reales. . . . .	51
6.2. Resultados obtenidos usando los datos frescos. (a) Estimación por OGD contra datos reales; (b) Estimación por ANFIS contra datos reales. . . . .	52
6.3. Gráficas de dispersión de las estimaciones obtenidas. (a) Estimación por OGD usando los datos de entrenamiento; (b) Estimación por OGD usando los datos frescos; (c) Estimación por ANFIS usando los datos de entrenamiento; (d) Estimación por ANFIS usando los datos frescos; . . . . .	52

6.4. Diferencia de errores entre valores $P_m$ altos y bajos. (a) Valor de error cuando el dato real medido es alto; (b) Valor de error cuando el dato real medido es bajo. . . . .	54
6.5. Comparación de los errores entre OGD y ANFIS usando los datos de entrenamiento. (a) RMSE; (b) nRMSE; (c) RMSPE; (d) MAE; (e) MAPE. . . . .	55
6.6. Comparación de los errores entre OGD y ANFIS usando los datos frescos. (a) RMSE; (b) nRMSE; (c) RMSPE; (d) MAE; (e) MAPE. . . . .	56
A.1. Crear un equipo. . . . .	64
A.2. Datos del equipo. . . . .	65
A.3. Equipo creado. . . . .	65
A.4. Conectar con el inversor. . . . .	66
A.5. Conectado. . . . .	66
A.6. Selección del periodo de descarga. . . . .	67
A.7. Inicio de descarga. . . . .	67
A.8. Visualización de la descarga de datos. . . . .	67
A.9. Descarga finalizada. . . . .	67
A.10.Exportación de datos a Excel. . . . .	68
A.11.Selección del periodo a exportar a Excel. . . . .	68
A.12.Visualización de la exportación de datos a Excel. . . . .	69
A.13.Selección del producto Solar.web . . . . .	69
A.14.Punto WiFi Solar.web . . . . .	70
A.15.Ingreso de datos para conexión LAN . . . . .	70
A.16.Porta de Fronius Solar.Web . . . . .	71
B.1. Consola de operación DAVIS. . . . .	72
B.2. Data Logger. . . . .	72
B.3. Software Weatherlink . . . . .	73
B.4. Nueva estación . . . . .	73
B.5. Configuración de la estación . . . . .	74
B.6. Puertos de comunicación . . . . .	74
B.7. Unidades de medición . . . . .	75
B.8. Ubicación por latitud y longitud . . . . .	75
B.9. Opción de descarga . . . . .	75
B.10.Opción para visualizar el histórico . . . . .	75
B.11.Histórico de datos . . . . .	76
B.12.Ruta para exportar el histórico . . . . .	76
B.13.Selección de la fecha a exportar . . . . .	76

# Índice de tablas

1.1. Radiación solar en lugares seleccionados de México (datos en $kWh/m^2$ al día). . . . .	3
1.2. Comparación de extensión territorial entre países europeos y el estado de Sonora en México. . . . .	4
4.1. Funciones de activación. . . . .	17
4.2. Funciones de membresía . . . . .	20
4.3. Pasos del aprendizaje híbrido . . . . .	25
5.1. Coeficientes de determinación . . . . .	30
5.2. Coeficientes por gradiente . . . . .	31
5.3. Valores de influencia . . . . .	31
5.4. Nomenclatura y simbología de las variables contempladas en el modelo. . . . .	33
5.5. Parámetros de las funciones de membresía del ANFIS 1 despues del entrenamiento. . . . .	37
5.6. Reglas difusas para el ANFIS 1. . . . .	37
5.7. Parámetros lineales tipo Takagi-Sugeno para la salida del ANFIS 1 despues del entrenamiento. . . . .	38
5.8. Parámetros de las funciones de membresía del ANFIS 2 despues del entrenamiento. . . . .	39
5.9. Reglas difusas para el ANFIS 2. . . . .	39
5.10. Parámetros lineales tipo Takagi-Sugeno para la salida del ANFIS 2 despues del entrenamiento. . . . .	40
5.11. Parámetros de las funciones de membresía del ANFIS 3 despues del entrenamiento. . . . .	41
5.12. Reglas difusas para el ANFIS 3. . . . .	41
5.13. Parámetros lineales tipo Takagi-Sugeno para la salida del ANFIS 3 despues del entrenamiento. . . . .	42
5.14. Parámetros de las funciones de membresía del ANFIS 4 despues del entrenamiento. . . . .	43
5.15. Reglas difusas para el ANFIS 4. . . . .	44
5.16. Parámetros lineales tipo Takagi-Sugeno para la salida del ANFIS 4 despues del entrenamiento. . . . .	45
6.1. Parámetros estadísticos obtenidos. . . . .	51
6.2. Resultados de valores de precisión. . . . .	57

# Lista de abreviaturas y símbolos

## Lista de abreviaturas

ANFIS	Adaptive Neuro-Fuzzy Inference System (Red Adaptable basada en Sistemas de Inferencia Difusa)
ATM	Presión atmosférica
CA	Corriente alterna
CD	Corriente directa
CZ	Proceso Czochralski
DNS	Domain Name System (Servidor de Nombres de Dominio)
DV	Dirección del viento
FM	Función de membresía
GMT	Greenwich Mean Time (Hora del Meridiano de Greenwich)
HR	Hora del día
HUM	Humedad
ID	Identificador
IP	Internet Protocol (Protocolo de internet)
LAN	Local Area Network (Red de Área Local)
MAE	Mean Absolute Error (Error Absoluto Medio)
MAPE	Mean Absolute Percentage Error (Error Porcentual Absoluto Medio)
nRMSE	Normalized Root Mean Square Error (Error Cuadrático Medio Normalizado)
OGD	Optimización por Gradiente Descendiente
PC	Personal Computer (Computadora personal)
POT	Potencia eléctrica
RAD	Radiación solar
RLM	Regresión Lineal Múltiple
RMSE	Root Mean Square Error (Raíz Cuadrada del Error Cuadrático Medio)
RMSPE	Root Mean Square Percentage Error (Error Porcentual Cuadrático Medio)
RNA	Red Neuronal Artificial
SFV	Sistema fotovoltaico
TCP/IP	Transmission Control Protocol/Internet Protocol (Protocolo de Control de Transmisión/Protocolo de Internet)
TEMP	Temperatura
USD	United States Dollars (Dólares americanos)
VV	Velocidad del viento
WiFi	Wireless Fidelity (Inalámbrico)

## Lista de símbolos

$W$	Watts
$W/m^2$	Watts por metro cuadrado
$V$	Volts
$A$	Amperes
$Hz$	Hertz
$^{\circ}F$	Grados Farenheit
$^{\circ}C$	Grados Celsius
$mmHg$	Milímetros de mercurio
$puHg$	Pulgadas de mercurio
$mbar$	milibares
$x_{n,q}$	Elemento de entrada para entrenamiento

$y_{n,r}$	Elemento de salida para entrenamiento
$D_{n,P}$	Conjunto de datos en general para entrenamiento
$n$	Cantidad de datos recolectados para entrenamiento
$q$	Cantidad de variables de entrada para entrenamiento
$r$	Cantidad de variables de salida para entrenamiento
$P$	Cantidad de variables en total para entrenamiento
$g$	Función de activación
$w$	Pesos de las entradas de una neurona
$E_p$	Error para la $p$ -ésima entrada del conjunto de datos
$L$	Cantidad de capas en una red neuronal
$m$	Elemento a considerar de un vector de salida en una red neuronal
$T_{m,p}$	Valor real de salida a obtener en una red neuronal
$O_{m,p}^L$	Valor estimado de salida en una red neuronal
$j$	Capa a considerar en una red neuronal
$i$	Número de la neurona dentro de una capa
$\alpha$	Parámetro de un nodo interno en una red neuronal
$\eta$	Razón de aprendizaje
$k_T$	Tamaño de paso
$\vec{I}$	Conjunto de variables de entrada
$S$	Conjunto de parámetros de una red neuronal
$S_1$	Conjunto de parámetros de la premisa
$S_2$	Conjunto de parámetros de la parte consecuente
$\Phi$	Vector de los parámetros de la parte consecuente
$M$	Cantidad de parámetros lineales de la parte consecuente
$a_m$	Coefficiente de la variable de entrada en una regresión lineal
$S_y$	Desviación estandar total
$S_{y/x}$	Desviación estandar de la estimación
$S_i$	Magnitud del error residual asociado con la variable dependiente antes de la regresión
$S_r$	Suma de errores cuadrados
$R$	Coefficiente de correlación
$R^2$	Coefficiente de determinación
$y_i$	Valor real medido de salida
$\bar{y}$	Valor estimado de salida
$X_{OGD}$	Matriz de entrada por Gradiente Descendiente
$y_{OGD}$	Vector de salida por Gradiente Descendiente
$h_\theta$	Valor de salida estimado por Gradiente Descendiente
$\theta$	Coefficiente característico por Gradiente Descendiente
$\epsilon$	Error entre el valor estimado y el real
$J[\theta]$	Función de costo para el Gradiente Descendiente
$K$	Muestra de datos a considerar actualmente
$z^i$	Regresor de orden $i$
$s_i$	Función implementada para entrenar el ANFIS $i$
$x_i$	Variable meteorológica a considerar
$h_\beta$	Valor de salida estimado por Regresión Lineal Múltiple
$\beta$	Coefficiente característico por Regresión Lineal Múltiple
$X_{RLM}$	Matriz de entrada por Regresión Lineal Múltiple
$y_{RLM}$	Vector de salida por Regresión Lineal Múltiple
$P_m$	Potencia medida
$P_e$	Potencia estimada
$N$	Cantidad total de muestras

# Capítulo 1

## Introducción

Con el paso del tiempo la necesidad de comprensión de los problemas de nuestro entorno ha sido parte clave en nuestra evolución, desde entender el medio ambiente y su relación con el planeta, así como su impacto en la forma de vida humana. Si bien al principio eran meras conjeturas empíricas, “si el cielo se nubla, entonces lloverá”, con el avance de la ciencia y tecnología hemos desarrollado métodos que puedan determinar de manera precisa dichos cambios meteorológicos e incluso predecirlos con una cierta probabilidad y como consecuencia, hemos aprendido a vivir comprendiéndolos. De igual manera y a causa de nuevos retos a través de los años, el cerebro humano ha ido evolucionando a lo largo de miles de años creando una inteligencia mayor que la de nuestros antepasados.

Por todo lo anterior, cualquier método que se asemeje al comportamiento del aprendizaje humano sea tecnológico o no, es sin lugar a dudas proclive a ser comprendido y aplicado con menor dificultad.

### 1.1. Problemática

La generación de energía eléctrica mundialmente es un tema de supervivencia humana, gracias a ella dependemos hoy en día. Transporte, refrigeración, maquinaria industrial, electrodomésticos, comunicaciones, seguridad, salud, entre otros más, son algunos ejemplos de sus aplicaciones.

Durante décadas hemos tenido diversas opciones de obtención de dicha energía; sin embargo, el común denominador de todas han sido los recursos no renovables teniendo como ejemplo desde el aceite de ballenas para iluminar los hogares con velas, hasta llegar al día de hoy donde utilizamos gas, petróleo o aceite; y aunque hasta a la fecha dichos recursos han resultado beneficiosos, su sustentabilidad es nula. Una vez agotados no podrán ser regenerados nunca más.

La creciente demografía mundial implica un aumento en la necesidad de energía, misma que obtenida de recursos no renovables, paulatinamente, será insostenible. Esto conlleva a un encarecimiento de los servicios debido a la dificultad progresiva para la obtención de dichos recursos siendo un ejemplo claro el petróleo, el cual necesita de tecnología más avanzada y costosa para satisfacer la demanda.

Desde tiempos remotos la búsqueda de nuevas formas para generar energía ha dado pie a nuevas investigaciones y experimentaciones que gracias a ellas actualmente conceptos como hidroeléctrica, solar o eólica han sido globalmente conocidos e implementados [1].

La energía solar es el recurso energético más abundante en la Tierra (Figura 1.1). La radiación global promedio que llega a la superficie terrestre al año es de  $1735 \text{ kWh/m}^2$ . La energía solar total de un año representa el suministro global de energía por 6,000 años, mientras que las reservas fósiles (petróleo) sólo representarían 46 años de suministro, el gas natural 58 años y el carbón 150 años de suministro global [2].

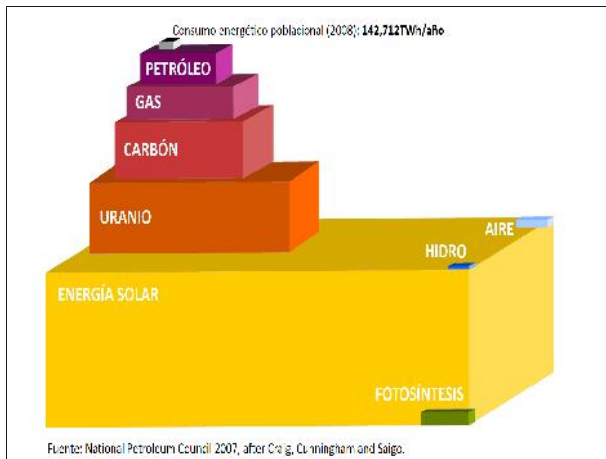


Figura 1.1: Total de recursos energéticos en la Tierra.

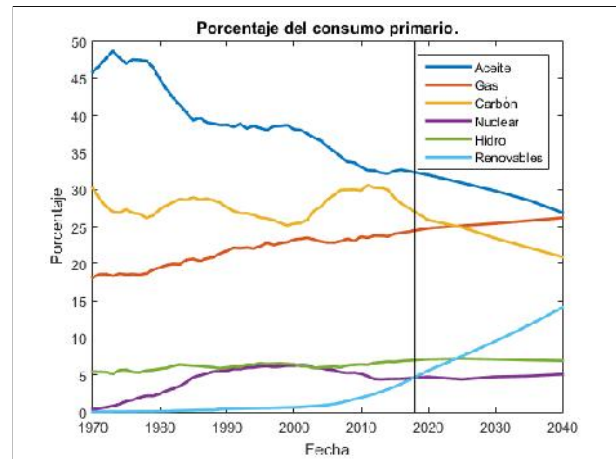


Figura 1.2: Predicción del uso de los recursos.

Si bien todo apunta al uso de energías renovables, en este caso solar, para la demanda energética en lugar de recursos no renovables como se ve en la Figura 1.2, poder determinar el comportamiento solar y más aun poder estimar la cantidad de radiación que incidirá de manera directa o global es un proceso estocástico [3]. De poder garantizar, con una cierta tasa de error, el comportamiento de la radiación solar sería de vital importancia para tanto empresas como para comunidades beneficiadas. La primera vería una disminución importante en los costos de generación y una mejoría en la logística de almacenamiento, mientras que la segunda gozaría de las ventajas directas de la primera.

## 1.2. Antecedentes

A través de la historia, la utilización de los recursos renovables como fuentes de energía ha sido siempre de interés para la humanidad. En China, durante el siglo II a.C., los hombres utilizaban los molinos de viento para moler granos o bombear agua, sin embargo fue hasta 1888 cuando Charles F. Brush construyó el molino de poste Brush en Cleveland, Ohio para generar electricidad usando el viento.

La fuerza del agua fue aprovechada para diversos usos, como moler grano o triturar materiales con alto contenido en celulosa para la producción de papel, hecho que atestiguan los numerosos molinos de agua conservados en diferentes partes del mundo. Se considera que la primera central hidroeléctrica fue la construida en Northumberland, Reino Unido, en el año de 1880 y un año después comenzó a utilizarse la energía procedente de las cataratas del Niágara para alimentar el alumbrado público. A finales de la década ya existían mas de 200 centrales tan sólo en Estados Unidos de América y Cánada.

Desde la antigüedad se inventaron artefactos capaces de hacer un uso útil de la radiación solar siendo los Griegos y Romanos los primeros; ya en el Siglo III a.C. fueron capaces de prender las antorchas de los rituales religiosos por medio de unos recipientes en forma parabólica con el interior reflejante. Alexandre Edmond Becquerel descubrió el efecto fotovoltaico en el año de 1839, mismo que consiste en la transformación directa de la luz en electricidad utilizando un semiconductor. Algunos años mas tarde, en 1877, el profesor de la King College de Londres William Grylls Adams junto con su alumno Richard Evans Day crearon la primera célula fotovoltaica de selenio. Sin embargo, fue hasta 1953 que Gerald Pearson de Laboratorios Bell patentó la primera célula fotovoltaica. [1].

La luz solar o radiación solar, medida en  $kW/m^2$ , es conocida como variable o parámetro meteorológico dado que afecta el estado del tiempo atmosférico. Otras variables tales como la temperatura, la humedad, la velocidad del viento o la presión atmosférica influyen a su vez en dicho estado. La radiación solar aumenta la temperatura del aire, incrementando su presión atmosférica; de igual manera es conocido que las nubes son vapor de agua concentrado en el aire, en otras palabras humedad y temperatura trabajando juntos lo cual dificulta la incidencia de radiación solar libre a la Tierra. Lo anterior demuestra que las variables meteorológicas, por estar confinadas dentro de la atmósfera, afectan y son afectadas entre sí, concepto importante si la generación de energía solar involucra al menos una de ellas [4].

La energía solar, aparte de la eólica, es hoy en día la fuente renovable de mayor uso mundialmente [3, 5]. Su obtención, a diferencia de muchas otras utilizadas actualmente, no supone ningún daño al ambiente y sus recursos superan por mucho a todas las demás [2, 5-7]. Algunos países como Alemania, Italia, España, Estados Unidos o China están a la cabeza en cuanto a investigaciones en energía solar, mientras que México, siendo un



país rico en radiación solar, con gran extensión territorial y teniendo estudios en energía solar, aún no cuenta con la investigación necesaria para compararse con los anteriores [6, 8–12].

La radiación solar y la extensión territorial son los factores clave para una buena producción fotovoltaica. La Figura 1.3 muestra el comportamiento de la radiación solar en territorio mexicano, describiendo una mayor incidencia en la parte Noroeste del país, siendo Sonora y Chihuahua dos de los estados con mayor radiación solar a nivel nacional [13]. La Tabla 1.1 comprueba la información de la Figura 1.3 mostrando un promedio anual de la radiación solar en varias ciudades de México [14].

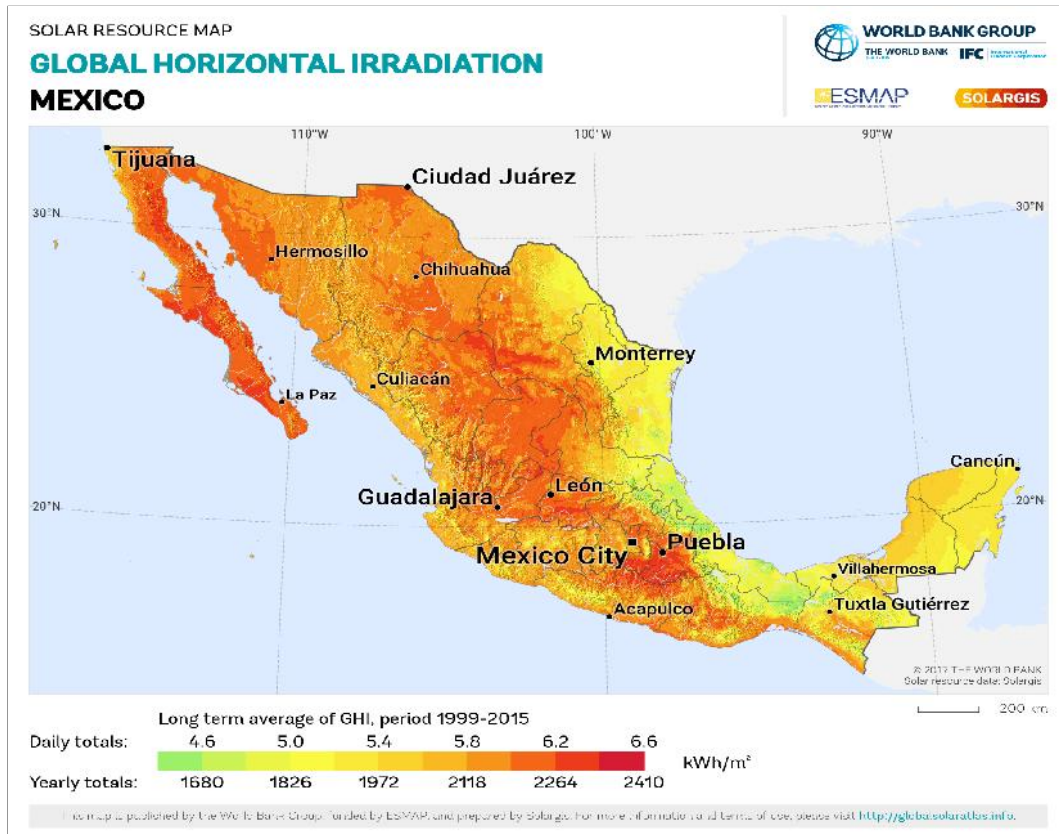


Figura 1.3: Atlas de la radiación solar en México.

Tabla 1.1: Radiación solar en lugares seleccionados de México (datos en kWh/m<sup>2</sup> al día).

Estado	Ciudad	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Prom
Sonora	Hermosillo	4.0	4.6	5.4	6.6	8.3	8.5	6.9	6.6	6.7	6.0	4.7	3.9	6.0
Sonora	Guaymas	4.5	5.7	6.5	7.2	7.3	6.8	5.9	5.8	6.3	5.9	5.0	5.6	5.9
Chihuahua	Chihuahua	4.1	4.9	6.0	7.4	8.2	8.1	6.8	6.2	5.7	5.2	4.6	3.8	5.9
SLP	SLP	4.3	5.3	5.8	6.4	6.3	6.1	6.4	6.0	5.5	4.7	4.2	3.7	5.4
Zacatecas	Zacatecas	4.9	5.7	6.6	7.5	7.8	6.2	6.2	5.9	5.4	4.8	4.8	4.1	5.8
Guanajuato	Guanajuato	4.4	5.1	6.1	6.3	6.6	6.0	6.0	5.9	5.8	5.2	4.8	4.6	5.6
Aguascalientes	Aguascalientes	4.5	5.2	5.9	6.6	7.2	6.3	6.1	5.9	5.7	5.1	4.8	4.0	5.6
Oaxaca	Salina Cruz	5.4	6.3	6.6	6.4	6.1	5.0	5.6	5.9	5.2	5.9	5.7	5.2	5.8
Oaxaca	Oaxaca	4.9	5.7	5.8	5.5	6.0	5.4	5.9	5.6	5.0	4.9	4.8	4.4	5.3
Jalisco	Colotlán	4.6	5.7	6.5	7.5	8.2	6.6	5.8	5.6	5.8	5.3	4.9	4.1	5.9
Jalisco	Guadalajara	4.6	5.5	6.3	7.4	7.7	5.9	5.3	5.3	5.2	4.9	4.8	4.0	5.6
Durango	Durango	4.4	5.4	6.5	7.0	7.5	6.8	6	5.6	5.7	5.1	4.8	3.9	5.7
Baja California	La Paz	4.4	5.5	6.0	6.6	6.5	6.6	6.3	6.2	5.9	5.8	4.9	4.2	5.7
Baja California	San Javier	4.2	4.6	5.3	6.2	6.5	7.1	6.4	6.3	6.4	5.1	4.7	3.7	5.5
Baja California	Mexicali	4.1	4.4	5.0	5.6	6.6	7.3	7.0	6.1	6.1	5.5	4.5	3.9	5.5
Querétaro	Querétaro	5.0	5.7	6.4	6.8	6.9	6.4	6.4	6.4	6.3	5.4	5.0	4.4	5.9
Puebla	Puebla	4.9	5.5	6.2	6.4	6.1	5.7	5.8	5.8	5.2	5.0	4.7	4.4	5.5
Hidalgo	Pachuca	4.6	5.1	5.6	6.8	6.0	5.7	5.9	5.8	5.3	4.9	4.6	4.2	5.4

La Tabla 1.2 muestra una comparación de extensión territorial entre algunos países europeos con avances importantes en el campo de la energía fotovoltaica y el estado de Sonora, de la cual se puede apreciar la cercanía de este último con los países “primermundistas” si se considera que Sonora corresponde al 9.4% de la superficie de México [15–18]. En la Figura 1.4 se visualiza el comportamiento de la radiación global horizontal en el mundo [19]. De igual manera si se compara México con Europa se puede observar que el único país que tiene una incidencia de radiación notoria es España con un valor máximo entre 4.8 y 5.4  $kWh/m^2$  y aun así el primero lo supera tanto en territorio de incidencia como en intensidad de radiación con un promedio entre 5.66 y 6.15  $kWh/m^2$  (Figura 1.3), incluso superando a China quien en su mayoría contempla valores de 4.6  $kWh/m^2$  [20].

Tabla 1.2: Comparación de extensión territorial entre países europeos y el estado de Sonora en México.

Lugar	Extensión ( $Km^2$ )
Sonora, México	184,934
España	498,980
Alemania	348,672
Italia	294,140

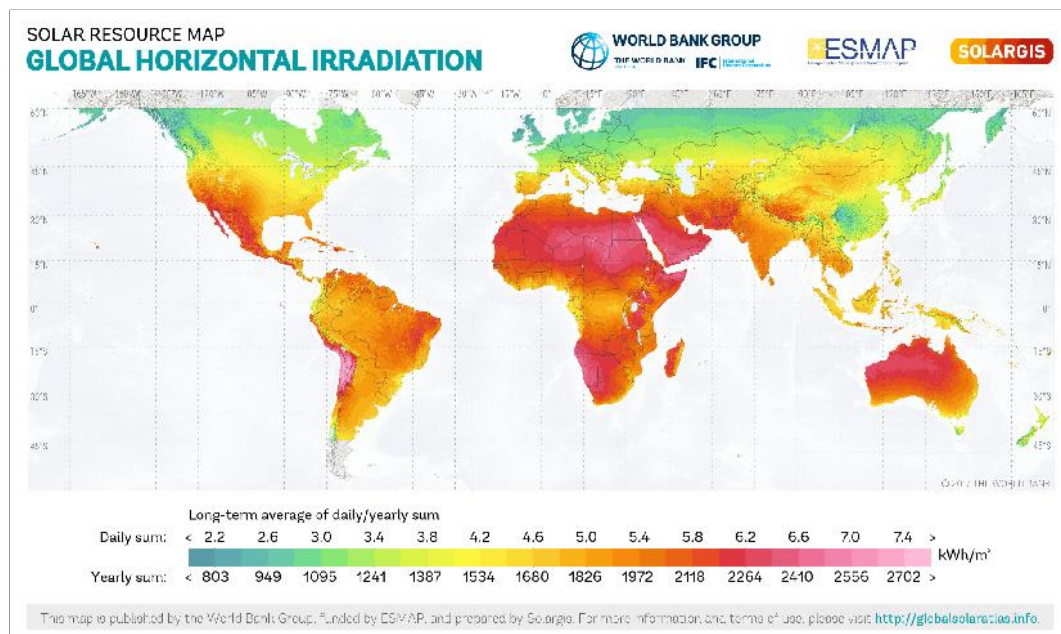


Figura 1.4: Radiación global horizontal mundial.

Las tecnologías solares se caracterizan dependiendo la forma en que capturan, convierten y distribuyen la luz solar, tales como sistemas fotovoltaicos, y de los correspondientes requerimientos para su almacenamiento para consecuentemente alimentar la red eléctrica. Sin embargo, la mayoría de las instalaciones fotovoltaicas en la actualidad no monitorean los factores o variables meteorológicas, de hacerlo se alcanzaría un mejor entendimiento de su contribución en el área energética encontrando estrategias más efectivas para lograr su adaptación y predicción [8, 10, 11, 21–24].

Muchos trabajos de investigación han sido realizados internacionalmente en el campo de los sistemas fotovoltaicos y la generación de energía, así como estudios sobre las relaciones entre variables meteorológicas y la potencia eléctrica generada. En [10] se presenta un análisis sobre la información obtenida a lo largo de un año de radiación solar y potencia fotovoltaica alrededor de 44 locaciones diferentes de Arabia Saudita probando que la temperatura en el sitio afecta considerablemente la eficiencia del sistema fotovoltaico.

Similarmente, existen muchos trabajos aplicando métodos estadísticos e inteligentes para estimar los comportamientos de varios sistemas e incluso predecirlos [25–28]. Estadísticamente, la aplicación de la regresión lineal es considerada para numerosos estudios en distintas áreas por su facilidad de implementación y simplicidad de carga computacional; en [29] este método se aplica para analizar las pérdidas humanas, costos de daños y de recuperación debido a desastres naturales en la República de Korea en el periodo de 2000 al 2015 tomando en

cuenta vientos extremos, nevadas intensas, tifones y fuertes lluvias. Aun así, aunque este método tiene fuertes ventajas, está limitado por su matemática y su precisión al momento de estimar un resultado, depende completamente de la cantidad de datos recopilados y la correlación que tienen con la variable que se quiere estimar.

Son los llamados métodos inteligentes los que han probado su mejoría sobre los estadísticos. Capaces de representar, precisamente, procesos lineales y no lineales, siendo los no lineales su mayor fortaleza. Aún así, independientemente del método implementado, la estimación será mas precisa si la cantidad de datos recopilados es una muestra considerable, la correlación con el dato que se quiere estimar es alta y el tiempo de registro entre un dato y el siguiente es pequeño teniendo en cuenta la razón de cambio del valor a estimar. La ventaja de las técnicas inteligentes sobre los métodos estadísticos es su capacidad de aprendizaje y adaptación lo que les permite mejorar continuamente para que la respuesta sea más cercana a la esperada.

Gran cantidad de trabajos involucran estos métodos para abordar temas relacionados con la potencia fotovoltaica. En [30] se mencionan los efectos de algunas variables meteorológicas en la generación de energía, pero no existe un modelo representativo de la planta y toda la información se genera experimentalmente. En [31] se aplica un método estadístico para predecir la energía generada por una planta solar aunque para este método es necesaria una base de datos de 30 plantas de diferentes locaciones cercanas al punto de interés. De igual manera no cuenta con medidas reales de potencia del sitio y la carga computacional es grande. En [32] se realiza un análisis de los factores climáticos y datos solares del desierto de Atacama; sin embargo, la información recopilada para el estudio son promedios calculados cada 10 minutos y las mediciones de la potencia son estimaciones. En [33] una Red Neuronal Artificial (RNA) se usa para obtener el modelo y predecir la energía fotovoltaica; sin embargo, la radiación solar es la única variable meteorológica analizada. En [34] diferentes técnicas RNA se utilizan para realizar un estudio comparativo entre sistemas para predecir datos de energía térmica fotovoltaica; sin embargo, debido a que los sensores de radiación solar son costosos y requieren mantenimiento periódico, algunos resultados emplearon valores estimados de radiación solar usando RNA. En [6] se establece que un sistema fotovoltaico es afectado por muchas condiciones meteorológicas y se crea un modelo predictivo donde la temperatura, la radiación solar, la dirección y velocidad del viento están involucrados. En [35] se aplica una red neuronal; sin embargo, la información recopilada es registrada cada 3 horas para el año 2014 y cada hora para el año 2016. En [36] se consideran los caprichos de la naturaleza para obtener un modelo basado en RNA-ANFIS y pronosticar la generación fotovoltaica y de energía eólica. En [37] se prueba que un sistema adaptable de inferencia neuro-difusa provee una herramienta útil para estimar la temperatura en sistemas fotovoltaicos. En [38] se busca mejorar la predicción de la productividad de la destilación solar implementando un ANFIS (Adaptive Neuro-Fuzzy Inference System) debido a su simple mantenimiento y accesible costo.

Por todo lo anterior, y debido a que no existe ningun precedente mexicano, este trabajo presenta el primer modelo mexicano de estimación a través de un método inteligente en su modo predictivo que permita obtener la potencia fotovoltaica de salida de manera autorecursiva utilizando las variables meteorológicas así como datos de la potencia registradas en la ciudad de Hermosillo, Sonora. Este estudio permitirá fundar una base para diferentes y múltiples desarrollos, tales como el dimensionamiento de sistemas fotovoltaicos contemplando las condiciones de su ubicación geográfica, con el objetivo de beneficiar a las tecnologías renovables así como al consumidor. Para llevar a cabo el modelo primeramente es necesario aplicar el concepto de correlación, coeficiente de determinación y OGD (Optimización por Gradiente Descendiente) para identificar las variables que mayor influencia tienen sobre la energía a generar y poder ser utilizadas para dicho modelo. De igual manera la cantidad de datos recopilados para el entrenamiento del método inteligente abarca un periodo de 6 meses y el tiempo entre un dato y el siguiente es de 5 minutos.

## 1.3. Objetivos

### 1.3.1. Objetivo general

Desarrollar un modelo predictivo inteligente para la producción de energía eléctrica en un sistema fotovoltaico.

### 1.3.2. Objetivos específicos

- Analizar la estructura y funcionamiento de un sistema fotovoltaico (SFV) sin seguimiento solar.
- Comprender la relación de variables ambientales y la producción de energía eléctrica en un SFV.
- Comprender los diversos modelos predictivos que existen actualmente en producción de energía eléctrica a través de SFV.

- Desarrollar un modelo inteligente capaz de estimar la producción de energía eléctrica en un SFV basado en las variables meteorológicas más importantes del sitio.
- Comparar el modelo obtenido con la producción eléctrica de un sistema fotovoltaico real que se encuentra instalado en la Universidad de Sonora, en la ciudad de Hermosillo, Sonora.
- Comparar el desempeño del modelo inteligente con el de al menos otro método.

## 1.4. Aportación

Este trabajo busca a futuro generar un mejor entendimiento de la energía solar como recurso renovable así como de las variables meteorológicas que influyen en la generación de la misma, consecuentemente permitirá a la sociedad implementar las tecnologías fotovoltaicas más óptimas para obtener una mayor generación de energía eléctrica a menor costo y con la mayor eficiencia energética. Una planeación cuidadosa es requerida para administrar la futura demanda de electricidad por sistemas fotovoltaicos debido a su creciente demanda en México [39, 40]. Por lo tanto, es vital comprender la influencia de las variables meteorológicas en el consumo de energía en el cual un mejor entendimiento puede contribuir en una estrategia más útil para alcanzar la eficiencia energética para el país [23, 24].

## 1.5. Organización de la tesis

En el Capítulo 1 se expone una breve introducción a los sistemas fotovoltaicos y su uso e importancia actualmente explicando la problemática abordada en este trabajo, así mismo como la estrategia para realizarlo y sus aportaciones.

En el Capítulo 2 se mencionan detalladamente los sistemas fotovoltaicos, características y componentes necesarios para implementar una planta solar.

En el Capítulo 3 se detalla la estación meteorológica utilizada para este trabajo la cual permite la obtención y registro de los datos meteorológicos necesarios para modelar el método inteligente.

En el Capítulo 4 se mencionan los diferentes métodos inteligentes involucrados para la realización del modelo final: redes neuronales, sistemas difusos y redes adaptables basadas en sistemas de inferencia difusas.

En el Capítulo 5 se presenta el modelo implementado basado en métodos inteligentes el cual permite la estimación de la potencia eléctrica fotovoltaica a través de las variables meteorológicas registradas en el sitio aplicando el software MATLAB/Simulink<sup>®</sup>. Dicho modelo se adecúa en la modalidad de predictor de la potencia eléctrica fotovoltaica y se detalla su implementación y comparación con los datos reales.

En el Capítulo 6 se valida la efectividad y precisión del modelo inteligente al exponer una comparación del sistema neurodifuso obtenido contra dos métodos estadísticos, así como la implementación de un análisis utilizando diversos errores.

En el Capítulo 7 se muestra la conclusión del trabajo mencionando su importancia y los posibles trabajos futuros a realizar.

En el Apéndice A se explica el proceso para la configuración del inversor el cual registra los datos de potencia eléctrica fotovoltaica, y se detalla el procedimiento para la descarga de sus respectivos datos.

En el Apéndice B se detallan ciertas características técnicas de la estación meteorológica y el procedimiento para la descarga de sus respectivos datos.

## Capítulo 2

# Conceptos de un sistema fotovoltaico y su funcionalidad

### 2.1. Constitución de un sistema fotovoltaico

#### 2.1.1. Panel solar

El panel solar o generador fotovoltaico consta de un conjunto de celdas solares conectadas entre sí para la obtención de energía y su posterior aprovechamiento.

Las celdas fotovoltaicas de silicio cristalino son las celdas solares más populares en el mercado y proveen la mayor eficiencia de conversión de energía entre todas las celdas solares y módulos comerciales. Se usa el silicio debido a que es seguro para el medio ambiente y representa el 26 % del material de la corteza terrestre.

Existen varios tipos de paneles fotovoltaicos dependiendo las características de creación de las celdas solares.

- Silicio
  - Tecnología cristalina
    - Monocristalino (16 %-20 % de eficiencia)
    - Policristalino (12 %-14 % de eficiencia)
  - Capa delgada de silicio (8 %-12 % de eficiencia)
- Capas delgadas de nuevos materiales
  - Teluro de Cadmio (CdTe)
  - Deseleniuro de indio-cobre
- Otros
  - Células multiunión (Arseniuros de Indio-Galio) y orgánicas

Entre las celdas solares más conocidas se encuentran las monocristalinas y las policristalinas. Las primeras se producen a partir de “oblas” de silicio pseudo-cuadradas cortadas de lingotes en columna crecidos por el proceso Czochralski (CZ). Las celdas solares policristalinas, por otro lado, se fabrican con substratos cuadrados de silicio cortados de lingotes policristalinos crecidos en crisoles de cuarzo [5,41].

Un recubrimiento de nitruro de silicio u óxido de titanio es sobrepuesto en la superficie así como una capa micrométrica de estructuras piramidales para lograr la reducción de pérdida de luz por reflexión.

Para que el silicio funcione como productor de energía, se introducen “impurezas” (átomos) en el silicio. Se denomina proceso de dopado. Las celdas solares de silicio cristalino tienen un alto dopaje tipo *n* de fósforo (produce electrones) y uno tipo *p* de boro (acepta electrones) en la superficie frontal para formar la unión *p-n*. La superficie posterior de tipo *p* está formada por substratos de silicio para suprimir la recombinación de cargadores minoritarios (electrones fotogenerados).

Las características de la celda solar y a su vez del panel en sí buscan obtener la mejor eficiencia en cuanto al efecto fotovoltaico se trata el cual es el encargado de la conversión de la luz solar en energía eléctrica. La irradiancia (radiación que incide en un instante sobre una superficie determinada conocida como potencia y medida en  $W/m^2$ ) es energía emitida por el sol como resultado de reacciones de fusión nucleares y dicha energía llega a la Tierra en forma de partículas llamados fotones. Estas partículas carecen de carga o masa, sin embargo, cuentan con todos los tipos de radiación electromagnética. Cuando la celda solar es iluminada por el sol, la energía de los fotones de la luz incidente es convertida en electricidad de corriente directa a través del efecto fotovoltaico

como se ve en la Figura 2.1. La luz incidente genera pares electrón-hueco en el semiconductor, y por lo tanto un incremento en la concentración de cargadores minoritarios (electrones en la región de tipo  $p$  y huecos en la región de tipo  $n$ ) en la región de agotamiento. Este incremento en la concentración de cargadores minoritarios resulta en el flujo de cargadores minoritarios a través de la región de agotamiento a las regiones cuasineutrales. Estos cargadores fotogenerados causan el flujo de la corriente. Cuando la unión está en la condición de circuito abierto, no existe corriente alguna que pueda fluir a la unión  $p-n$ . Si una carga es conectada entre los electrodos de la unión  $p-n$ , una fracción de la corriente fotogenerada fluirá por el circuito externo. La diferencia de potencial entre las regiones tipo  $p$  y tipo  $n$  disminuirá debido a una caída de voltaje en la carga [42].




Figura 2.1: Efecto fotovoltaico en una celda p-n.



Figura 2.2: Sistema fotovoltaico UNISON.

El SFV utilizado en la tesis (Figura 2.2) es un conjunto de 10 paneles solares del tipo policristalino de la marca Phono Solar siendo el modelo PS310P-24T colocado en un ángulo fijo de  $25^\circ$  respecto a la horizontal. Cada panel tiene una razón de potencia de 310 Watts, una eficiencia de módulo del 15.98 %, una cantidad de  $6 \times 12$  celdas solares y un voltaje máximo del sistema de 1000V.

### 2.1.2. Batería

La batería en un SFV o batería solar es la encargada de almacenar la energía generada durante el día por el panel solar para su posterior uso durante la noche o en días de poca radiación solar.

De igual manera sirven para proveer una mayor corriente que la que logra entregar el panel fotovoltaico por sí solo, siendo el caso de varios aparatos trabajando al mismo tiempo.

Una batería se compone de varios acumuladores de 2V dentro del mismo con una corriente continua a 6, 12, 24 o 48V. Es el acumulador quien almacena la energía a través de un proceso electroquímico [43].

Los tipos de baterías se dividen en dos tipos:

- **Baterías de ciclo bajo**  
Están diseñadas para suplir una cantidad de corriente por un corto periodo de tiempo y soportar pequeñas sobrecargas sin perder electrolitos, como en el caso de las de automóviles. Sin embargo, estas baterías no soportan descargas profundas. Si se descargan repetidamente por debajo del 20 %, se acorta su vida útil considerablemente. Por lo tanto estas baterías no son una buena elección para sistemas solares fotovoltaicos.
- **Baterías de ciclo profundo**  
Están diseñadas para ser descargadas repetidamente hasta un 80 % de su capacidad. Esta característica las convierte en la mejor opción para sistemas de energía solar.

### 2.1.3. Regulador de carga

Para un correcto funcionamiento de la instalación es necesario implementar un sistema de regulación de carga en la unión entre los paneles solares y las baterías. Este elemento recibe el nombre de regulador y tiene como misión evitar situaciones de carga y sobredescarga de la batería, con el fin de alargar su vida útil.

El regulador trabaja en la parte relacionada con la carga, su misión es la de garantizar una carga suficiente al acumulador y evitar las situaciones de sobrecarga, y en la parte de descarga se ocupa de asegurar el suministro eléctrico diario suficiente y evitar la descarga excesiva de la batería.

Dado que los módulos solares tienen un voltaje nominal mayor que el de la batería, si no existiera regulador se podrían producir sobrecargas. El motivo de que este voltaje tenga dicho comportamiento se debe fundamentalmente a dos razones:

- Atenuar posibles disminuciones de voltaje por el aumento de la temperatura.
- Asegurar la carga correcta de la batería. Para ello el voltaje del panel deberá ser mayor que la tensión nominal de la batería.

El dimensionado de la instalación solar se realiza de manera que se asegure el suministro de energía en las peores condiciones de luminosidad solar. Por ello se toman como referencia los valores de irradiación en invierno. Esto puede provocar que en verano la energía aportada por los módulos solares sea en ocasiones casi el doble de los cálculos estimados, por lo que, si no se conecta el regulador entre los paneles y las baterías, el exceso de corriente podría llegar incluso a hacer hervir el electrolito de los acumuladores, con el riesgo que ello conlleva [44].

#### 2.1.4. Inversor

Es el dispositivo encargado de convertir la energía, obtenida del generador, de corriente directa (CD) a corriente alterna (CA) para su posterior uso en el consumo. Si bien el generador fotovoltaico crea la energía a partir de la incidencia de los rayos solares ésta es completamente directa limitando su funcionalidad notablemente ya que la mayoría de la maquinaria, desde uso doméstico hasta del tipo industrial, sólo trabaja con corriente alterna.

El inversor utilizado es un GALVO 3.1-1 de la marca Fronius (Figura 2.3) con una potencia máxima de 3.1kW (tal como lo especifica su nombre), voltaje de operación nominal CA de 208 a 240V a 60Hz, un rango de voltaje CD de operación de 165 a 440V y una corriente máxima CD de 20.0A.



Figura 2.3: Inversor FRONIUS GALVO 3.1-1

La función de un inversor es cambiar un voltaje de entrada en CD a un voltaje simétrico de salida en CA con magnitud y frecuencia deseadas. Tanto el voltaje de entrada como la frecuencia de salida pueden ser fijos o variables. Si se modifica el voltaje de entrada en CD y la ganancia del inversor se mantiene constante, es posible obtener un voltaje variable de salida. Por otra parte, si el voltaje de entrada en CD es fijo y por lo tanto no es controlable, se puede obtener un voltaje de salida variable si se varía la ganancia del inversor. Esto por lo general se hace utilizando algún tipo de modulación, como es la modulación por ancho de pulso PWM que

permite controlar tanto la ganancia como la frecuencia del inversor. La ganancia del inversor se puede definir como la relación entre el voltaje de salida en CA y el voltaje de entrada en CD.

En los inversores, las formas de onda del voltaje de salida deberían ser senoidales; sin embargo, en los inversores reales no son senoidales y contienen ciertos armónicos. Para aplicaciones de baja y mediana potencia, se pueden aceptar los voltajes de onda cuadrada o casi cuadrada; para aplicaciones de alta potencia, son necesarias las formas de onda de baja distorsión. Dada la disponibilidad de los dispositivos semiconductores de potencia de alta velocidad, es posible reducir significativamente el contenido armónico del voltaje de salida mediante diversas técnicas de conmutación.

Los inversores son ampliamente usados y algunas de sus aplicaciones pueden ser las siguientes:

- Controladores de motores de corriente alterna.
- Fuentes de poder ininterrumpibles (UPS).
- Fuentes de corriente alterna.
- Generadores o compensadores estáticos de potencia reactiva.

Los inversores pueden clasificarse básicamente en dos tipos:

- Inversores monofásicos.
- Inversores trifásicos.

Cada tipo de inversor puede utilizar dispositivos de conmutación con activación y desactivación controlada como lo son los transistores bipolares BJT, los transistores bipolares de compuerta aislada IGBT, los transistores de efecto de campo de metal-óxido MOSFET, los tiristores, entre otros [45].

## 2.2. Conclusiones del capítulo

Actualmente los SFV se utilizan ampliamente debido a que en cualquier parte del planeta se tiene radiación solar por lo que en cualquier ubicación se puede generar potencia fotovoltaica. Aunque la instalación e implementación de un sistema fotovoltaico supone un costo alto, el ahorro de energía y la eficiencia energética son beneficios a largo plazo tanto para el planeta en cuanto a energía no contaminante y para comunidades que carecen de infraestructura eléctrica. De igual manera, en zonas urbanas son cada vez más las cantidades de viviendas y edificios que optan por estos métodos renovables.



## Capítulo 3

# Datos meteorológicos

### 3.1. Estación meteorológica

Un sistema o proceso siempre cuenta con dos tipos de datos conocidos como datos de “entrada” y “salida”; los primeros son independientes en el sistema y normalmente deben ser recopilados, mientras que los segundos son los resultados que se necesitan encontrar y dependen completamente de los primeros. Para esta tesis los datos o variables de salida corresponden únicamente a la potencia fotovoltaica generada por el inversor mencionado en la sección 2.1.4. Para la obtención de los datos de entrada se utiliza la estación meteorológica VANTAGE PRO2 de la marca DAVIS la cual se muestra en la Figura 3.1. Dicha estación cuenta con sensores de lluvia, viento, temperatura y humedad ya integrados, así como una consola para la visualización fuera de sitio en tiempo real de las variables medidas. La consola también tiene la capacidad de medir ciertas variables en el lugar de ubicación de la misma. Es importante mencionar la posibilidad de llevar un seguimiento de las variables por internet a través de [www.weatherlink.com](http://www.weatherlink.com) así como vincularse con alguna otra página de supervisión.



Figura 3.1: Estación meteorológica VANTAGE PRO2

Las variables que monitorea la VANTAGE PRO2 son las siguientes:

- **Date:** Registra el día de la captura de datos con formato dd/mm/aa.
- **Time:** Registra la hora de la captura de datos con formato h:mm a/p.
- **Temp Out:** Registra la temperatura ambiente en °F.  
La temperatura es la magnitud física que expresa el grado o nivel de calor de los cuerpos o del ambiente.
- **Hi Temp:** Registra la máxima temperatura ambiente en un período en °F.
- **Low Temp:** Registra la mínima temperatura ambiente en un período en °F.
- **Out Hum:** Registra la humedad relativa ambiente en %.  
Expresión porcentual de la cantidad de vapor de agua presente en el aire con respecto a la máxima posible para condiciones dadas de presión y temperatura.
- **Dew Point:** Registra el punto de rocío en °F.  
El punto de rocío es la temperatura a la cual el aire debe ser enfriado para que ocurra la saturación, siempre que no haya un cambio en el agua contenida.
- **Wind Speed:** Registra la velocidad del viento en *m/s*.  
El viento es la corriente de aire producida en la atmósfera por causas naturales, como diferencias de presión o temperatura.
- **Wind Dir:** Registra la dirección del viento cardinalmente.
- **Wind Run:** Registra la cantidad de viento que pasa por la estación en un lapso de tiempo, ya sea en millas de viento o kilómetros de viento.
- **Hi Speed:** Registra la máxima velocidad del viento en un período.
- **Hi Dir:** Registra la dirección del viento predominante en un período.
- **Wind Chill:** Registra la sensación térmica ambiental en °F.  
La sensación térmica es la percepción de la temperatura ambiente en un sitio específico. El cuerpo humano calienta las moléculas del aire a su alrededor y éste a su vez transfiere calor a la piel. Si en el sitio la velocidad del viento es alta, la capa del aire calentado alrededor se alejará dando una sensación térmica baja. Sin embargo si la velocidad del viento es baja o nula la capa se mantendrá estacionaria y la sensación térmica de la persona será mayor, incluso que la temperatura ambiente. Es importante mencionar que arriba de los 33°C el viento no tiene efecto aparente sobre la temperatura.
- **Heat Index:** Registra el índice de calor.  
El índice de calor hace uso de la temperatura y la humedad para poder determinar la percepción del aire.
- **THW Index:** Registra el índice Temperatura-Humedad-Viento.  
Este índice determina una temperatura aparente de acuerdo a las tres variables.
- **Bar:** Registra la presión atmosférica.  
Es una presión que ejerce la atmósfera sobre todos los objetos inmersos en ella y cuyo valor normal al nivel del mar es de 760 mmHg, 29.92 puHg o 1013 mbar.
- **Rain:** Registra la cantidad de lluvia en *mm*.
- **Rain Rate:** Registra la intensidad de la lluvia en *mm/hora*.
- **Heat D-D:** Registra el grado de calentamiento por día (Heat Degree-Days).  
Un *heating degree day* es el monto de calor requerido para conservar una estructura a 18°C cuando la temperatura exterior permanece un grado abajo del umbral de los 18°C por 24 horas.
- **Cool D-D:** Registra el grado de enfriamiento por día (Cool Degree-Days).  
Un *cooling degree day* es el monto de enfriamiento requerido para conservar una estructura a 18°C cuando la temperatura exterior permanece un grado arriba del umbral de los 18°C por 24 horas.
- **In Temp:** Registra la temperatura en el interior, donde se encuentra ubicada la consola.
- **In Hum:** Registra la humedad en el interior, donde se encuentra ubicada la consola.
- **In Dew:** Registra el punto de rocío en el interior, donde se encuentra ubicada la consola.

- In Heat: Registra el índice de calor en el interior, donde se encuentra ubicada la consola.
- In EMC: ElectroMagnetic Compatibility. Registra el grado de integridad de la señal que se recibe desde los sensores.
- In Air Density: Registra la densidad del aire en el interior, donde se encuentra ubicada la consola.
- Wind Samp: Registra la cantidad de muestras tomadas del viento.
- Wind Tx: Indica si la transmisión de datos está activa.
- ISS Recept: Registra el porcentaje de recepción (calidad) en base a las muestras tomadas del viento.
- Arc. Int.: Registra el intervalo de tiempo para el almacenamiento de datos.

La Figura 3.2 representa la operatividad de la estación meteorológica de manera general para el monitoreo y registro de los datos. Como se aprecia, la estación recopila las variables ambientales correspondientes y de manera inalámbrica las envía a la consola la cual almacena y muestra en tiempo real dichos valores, este dispositivo a su vez recopila valores de la ubicación en la cual se encuentra instalada así como detalles de la señal y su calidad. Finalmente, la información obtenida se puede manipular al enviarla a una computadora por una conexión LAN.

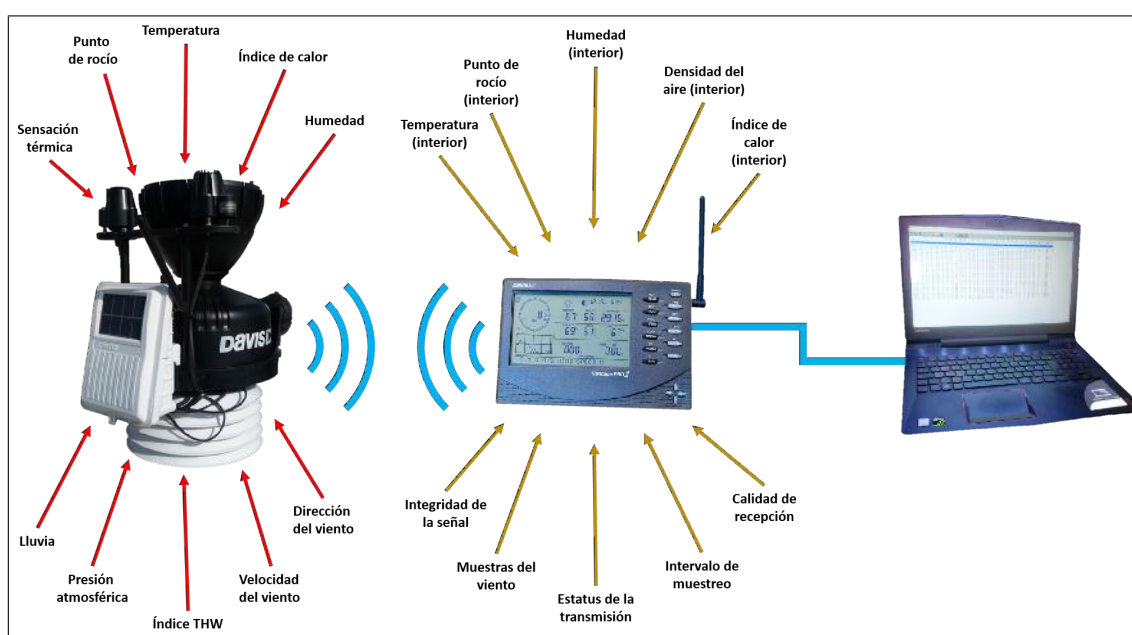


Figura 3.2: Esquema de funcionamiento de la estación VANTAGE PRO 2

### 3.2. Piranómetro

Para la obtención de datos de radiación solar, variable clave para la generación de potencia solar, se utilizó un piranómetro o solarímetro LI-COR (Figura 3.3) el cual mide la irradiancia solar en  $W/m^2$  y está basado en detectores fotovoltaicos (celdas solares). Estos dispositivos son baratos y fáciles de usar, su respuesta a niveles variables de radiación es esencialmente instantánea y es lineal con la radiación. El instrumento LI-COR tiene acoplado un difusor acrílico, el cual sustancialmente elimina la dependencia de respuesta sobre el ángulo de incidencia de la radiación.

Los detectores para los piranómetros de manera general deben tener una respuesta independiente de la longitud de onda sobre el espectro de energía solar. Además, deben tener una respuesta independiente del ángulo de incidencia de la radiación solar. Los detectores de casi todos los piranómetros están cubiertos con una o dos cubiertas semiesféricas de vidrio para protegerlos del viento u otros factores externos; las protecciones deben ser muy uniformes en su grosor para no provocar distribuciones irregulares de radiación sobre los detectores.

Existen 3 clases de radiación solar: radiación solar directa, difusa y global.

Se conoce como radiación directa, o rayo, a la radiación recibida del sol que no ha sido absorbida ni dispersada. La radiación solar que se mide fuera de la atmósfera es en su totalidad radiación directa, ya que no hay presencia de cuerpos o fenómenos que modifiquen su trayectoria. Sin embargo, cuando los rayos del sol cruzan la

atmósfera, una parte de ellos son absorbidos o dispersados y el resto logra tocar la superficie terrestre en forma directa. La radiación solar recibida en la superficie terrestre después que su dirección ha sido cambiada por la dispersión en la atmósfera es conocida como radiación difusa. La radiación que incide sobre una superficie también consiste de radiación solar dispersa proveniente del cielo y posiblemente la radiación solar reflejada por la tierra. La interacción de los rayos solares con las moléculas de aire y partículas de polvo provocan la dispersión de tales rayos. La radiación global o total es la suma de las radiaciones directa y difusa sobre una superficie. Es la medición más común de la radiación solar (radiación total sobre una superficie horizontal) [46].

El panel solar se encuentra orientado en un ángulo de  $25^\circ$  respecto a la horizontal para que logre obtener radiación solar directa en el momento de mayor incidencia solar durante el día, por lo que el piranómetro debe de estar orientado de igual manera. Lo anterior permite que el registro de ambos dispositivos sea coherente y así lograr evitar desfases o diferentes valores entre uno y otro durante el día.



Figura 3.3: Piranómetro.

### 3.3. Conclusiones del capítulo

La necesidad de registrar y monitorear las variables meteorológicas es esencial si se toma en consideración un sistema que involucra al menos una de ellas, en este caso la radiación solar. De igual manera, la correcta elección del equipo de medición es fundamental. Debido a que todo componente físico intrínsecamente cuenta con pérdidas de voltaje, corriente, térmicas, etc., un sistema físico nunca podrá ser perfecto y es necesario optar por aquel que entregue el desempeño adecuado u óptimo para el trabajo a realizar.

# Capítulo 4

## Sistemas inteligentes

Existen muchos trabajos sobre métodos inteligentes para estimar los comportamientos de diferentes sistemas e incluso predecirlos [27, 28]. Así mismo los métodos inteligentes tienen una gran ventaja al poder representar de manera precisa procesos tanto lineales como no lineales. Un método inteligente consta de un proceso que aprende constantemente para generar una salida lo más próxima posible a la variable requerida entre los cuales los más conocidos son la Red Neuronal Artificial (RNA), sistema difuso y el ANFIS (Adaptive Neuro-Fuzzy Inference System o Red Adaptable basada en Sistemas de Inferencia Difusa) [47].

### 4.1. Red Neuronal Artificial

#### 4.1.1. Generalidades

Una RNA imita la manera en que el cerebro humano procesa información. Como su nombre lo indica implica una estructura de unidades (neuronas o nodos) trabajando en conjunto altamente conectadas entre sí a través de enlaces (sinapsis) con pesos.

Las RNA pueden aplicarse a varias categorías según su función: clasificación de patrones, función de aproximación, predicción, optimización, recuperación por contenido y procesos de control. En clasificación de patrones se utilizan para clasificar terrenos desde imágenes satelitales o clasificación de olor en aguas residuales. La función de aproximación, también llamada regresión, genera una función a partir de un conjunto de datos de entrenamiento; aplicada en el modelado del sedimento de ríos, captación de agua para suministro o la estimación de la distribución de nitratos en aguas subterráneas. Las RNA también se usan para predicción, estimando una salida a partir de muestras previas en una serie de tiempo como la predicción meteorológica, calidad del aire o del agua. Como optimización para maximizar o minimizar una función de costo sujeta a restricciones tal como en ecuaciones de calibración. La recuperación por contenido genera memoria incluso si los datos de entrada son parciales o están distorsionados, dicha aplicación es apreciable en la generación de sustitutos en calidad de agua a través de imágenes satelitales. En cuanto a procesos de control se considera el control de velocidad de motores como una de sus muchas aplicaciones [48].

Como se aprecia en la Figura 4.1 cada nodo, representado por un círculo o un cuadrado, está conectado por enlaces (flechas) a otros nodos; cada uno de estos enlaces transporta la salida del nodo anterior como entrada del nodo siguiente; sin embargo, se debe tener en cuenta que no todos los enlaces afectan con la misma importancia al nodo consecuente. Para un mejor entendimiento se toma en consideración el siguiente ejemplo:

*“En un salón de clases el profesor explica los criterios de evaluación de la materia y sus respectivos porcentajes: 50 % examen, 20 % tareas, 30 % proyecto final y 10 % asistencia.”*

El profesor explica que aunque todos los criterios se consideran para la calificación final, no todos comparten la misma influencia. Así mismo actúa una red neuronal donde cada enlace entre neuronas maneja una influencia diferente llamada *peso* y la cual durante el entrenamiento se va ajustando para obtener la salida más cercana posible a la requerida.

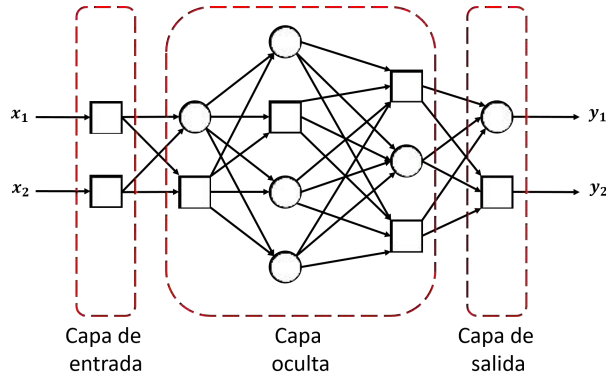


Figura 4.1: Red adaptable

### 4.1.2. Parámetros y funciones de activación

Tomando en cuenta el ejemplo del salón de clases, cada criterio de evaluación tiene su respectivo método de calificar (no se califica de igual manera un examen que la asistencia), así mismo cada nodo trabaja y obtiene una salida de manera única respecto a las demás neuronas. Para reflejar diferentes capacidades adaptables, se utilizan nodos redondos y cuadrados como se ve en la Figura 4.1. Un nodo redondo emplea operaciones fijas las cuales no van a resultar alteradas en ningún momento (la sumatoria o producto de sus entradas) a diferencia de un nodo cuadrado o adaptable el cual aplica las llamadas *funciones de activación*. Dichas funciones pueden variar de neurona en neurona, y la elección de cada una depende de la relación entrada-salida involucrada en ella. Para poder describir completamente una función de activación es necesario conocer sus correspondientes *parámetros*; si se habla de una función escalón el parámetro necesario es el valor de  $x$  en que la salida conmuta de  $-1$  a  $+1$ .

Ahora bien, algunos o todos los nodos pueden ser adaptables, lo cual significa que sus salidas dependen de los parámetros pertenecientes a esos nodos, y la regla de aprendizaje específica la manera en que esos parámetros deben ir cambiando para minimizar el error medido. Si bien la regla de aprendizaje conocida como método de gradiente descendente es notoria por su lentitud y tendencia a quedar próximo al mínimo local, el híbrido es actualmente uno de los más usados debido a su rapidez sobre el gradiente para el proceso de aprendizaje.

La arquitectura de una RNA consta de una capa de entrada que contiene una neurona por cada variable de entrada, una capa de salida con una neurona por cada variable de salida y entre ambas una cierta cantidad de capas las cuales conforman la *capa oculta* donde se crean todos los enlaces de la red. Para el caso de la Figura 4.1 la capa oculta está formada por 3 capas.

Normalmente se considera al compendio de datos recolectados para entrenar una RNA como una matriz de  $P$  columnas por  $m$  filas como se muestra en la Ecuación (4.1)

$$D = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,q} & y_{1,1} & y_{1,2} & \cdots & y_{1,r} \\ x_{2,1} & x_{2,2} & \cdots & x_{2,q} & y_{2,1} & y_{2,2} & \cdots & y_{2,r} \\ x_{3,1} & x_{3,2} & \cdots & x_{3,q} & y_{3,1} & y_{3,2} & \cdots & y_{3,r} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{n,1} & x_{n,2} & \cdots & x_{n,q} & y_{n,1} & y_{n,2} & \cdots & y_{n,r} \end{bmatrix} = \begin{bmatrix} D_{1,1} & D_{1,2} & D_{1,3} & \cdots & D_{1,P} \\ D_{2,1} & D_{2,2} & D_{2,3} & \cdots & D_{2,P} \\ D_{3,1} & D_{3,2} & D_{3,3} & \cdots & D_{3,P} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ D_{n,1} & D_{n,2} & D_{n,3} & \cdots & D_{n,P} \end{bmatrix} \quad (4.1)$$

donde  $x$  simboliza los datos de entrada,  $y$  son los datos de salida y  $D$  son los datos de manera general tanto de entrada y salida;  $n$  es la cantidad de datos recolectados,  $q$  es la cantidad de variables de entrada,  $r$  es la cantidad de variables de salida (en caso de que exista más de una) y  $P$  es la cantidad de variables en general contemplando entradas y salidas. Para la RNA de la Figura 4.1 la matriz de datos correspondiente está constituida por 4 columnas ( $x_1, x_2, y_1, y_2$ ).

Como se mencionó anteriormente, una neurona interna involucra entradas y una salida la cual está descrita por la Ecuación (4.2)

$$y(x) = g\left(\sum_{i=0}^n w_i x_i\right) \quad (4.2)$$

donde ( $w_0, \dots, w_m$ ) son los pesos de las entradas y  $g$  es la función de activación, usualmente una función escalón o sigmoide. Otras de las funciones de activación más conocidas son la identidad, lineal a tramos, gaussiana y

sinusoidal como se ve en la Tabla 4.1 [49].

Tabla 4.1: Funciones de activación.

Tipo	Función	Rango	Gráfica
Identidad	$f(x) = x$	$[-\infty, +\infty]$	<p><b>Función identidad</b></p>
Escalón	$f(x) = \text{sign}(x)$ $f(x) = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	<p><b>Función escalón</b></p>
Lineal a tramos	$f(x) = \begin{cases} -1, & x < -1 \\ x, & -1 \leq x \leq 1 \\ 1, & x > 1 \end{cases}$	$[-1, +1]$	<p><b>Función lineal a tramos</b></p>
Sigmoide	$f(x) = \frac{1}{1+e^{-x}}$ $f(x) = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	<p><b>Función sigmoide</b></p>
Gaussiana	$f(x) = Ae^{-Bx^2}$	$[0, +1]$	<p><b>Función gaussiana</b></p>
Sinusoidal	$f(x) = A \sin(\omega x + \varphi)$	$[-1, +1]$	<p><b>Función sinusoidal</b></p>

### 4.1.3. Entrenamiento

Una RNA, durante el proceso de entrenamiento, utiliza la mayoría de los datos recopilados para ajustar tanto los parámetros de las funciones de activación como los pesos de los enlaces, estos son conocidos como *datos de entrenamiento*. Los datos restantes son utilizados para validar que la red fue entrenada satisfactoriamente y se llaman *datos de prueba o datos frescos*.

Suponiendo que el conjunto de datos de entrenamiento tiene  $P$  entradas, se puede definir el *error* para la  $p$ -ésima ( $1 \leq p \leq P$ ) entrada del conjunto de datos como la suma de los errores cuadrados:

$$E_p = \sum_{m=1}^L (T_{m,p} - O_{m,p}^L)^2 \quad (4.3)$$

donde  $L$  es la cantidad de capas,  $T_{m,p}$  es el  $m$ -ésimo componente del  $p$ -ésimo vector de salida a obtener y  $O_{m,p}^L$  es el  $m$ -ésimo componente del vector de salida actual producido por la presentación del  $p$ -ésimo vector de entrada; en otras palabras es una diferencia entre el valor real y el estimado.

Considerando un procedimiento de aprendizaje que aplica el gradiente descendente, es necesario calcular la razón de error  $\partial E_p / \partial O$  para el  $p$ -ésimo dato de entrenamiento y para cada nodo de salida  $O$ .

La razón de error para el nodo de salida  $(L, i)$  puede ser calculado de la Ecuación (4.4):

$$\frac{\partial E_p}{\partial O_{i,p}^L} = -2 (T_{i,p} - O_{i,p}^L) \quad (4.4)$$

Para el nodo interno en  $(j, i)$ , la razón de error puede ser derivada a través de la regla de la cadena:

$$\frac{\partial E_p}{\partial O_{i,p}^j} = \sum_{m=1}^{j+1} \frac{\partial E_p}{\partial O_{m,p}^{j+1}} \frac{\partial O_{m,p}^{j+1}}{\partial O_{i,p}^j} \quad (4.5)$$

donde  $1 \leq j \leq L - 1$ . Por lo anterior, la razón de error de un nodo interno puede ser expresado como la combinación lineal de las razones de error de los nodos en la siguiente capa.

Durante el proceso de entrenamiento, los parámetros de cada nodo se ajustan a través de la aplicación de la Ecuación (4.5) enfocada en dicho parámetro. Si se supone  $\alpha$  como uno de los parámetros, entonces se obtiene la Ecuación (4.6) de la cual  $S$  es el conjunto de nodos cuyas salidas dependen de  $\alpha$  y a su vez la derivada del error total  $E$  respecto a  $\alpha$  se expresa con la Ecuación (4.7)

$$\frac{\partial E_p}{\partial \alpha} = \sum_{O^* \in S} \frac{\partial E_p}{\partial O^*} \frac{\partial O^*}{\partial \alpha} \quad (4.6)$$

$$\frac{\partial E_p}{\partial \alpha} = \sum_{p=1}^P \frac{\partial E_p}{\partial \alpha} \quad (4.7)$$

En consecuencia, la Ecuación (4.8) describe la fórmula de actualización para el parámetro genérico  $\alpha$

$$\Delta \alpha = -\eta \frac{\partial E}{\partial \alpha} \quad (4.8)$$

siendo  $\eta$  la velocidad o razón de aprendizaje expresada por la Ecuación (4.9)

$$\eta = \frac{k_T}{\sqrt{\sum \alpha \left( \frac{\partial E}{\partial \alpha} \right)^2}} \quad (4.9)$$

donde  $k_T$  es el tamaño de paso, es decir, la longitud de cada transición gradiente en el espacio de parámetros el cual permite variar la velocidad de convergencia [49, 50].

Tomando en cuenta el entrenamiento híbrido, un criterio que se puede utilizar para diferenciar las reglas de aprendizaje se basa en considerar si la red puede aprender durante su funcionamiento habitual o si el aprendizaje supone la desconexión de la red, es decir, su inhabilitación hasta que el proceso termine. El primer caso es conocido como aprendizaje *en línea* y su fórmula de actualización está basada en la Ecuación (4.6), mientras que el segundo se trata del aprendizaje *fuera de línea* y está basado en la Ecuación (4.7).

Cuando el aprendizaje es fuera de línea, se distingue entre una *fase de aprendizaje o entrenamiento* y una *fase de operación o funcionamiento*, existiendo un conjunto de datos de entrenamiento y un conjunto de datos de test o prueba, que serán utilizados en la correspondiente fase. Además, los pesos de las conexiones permanecen fijos después que termina la etapa de entrenamiento de la red. Debido precisamente a su carácter estático, estos



sistemas no presentan problemas de estabilidad en su funcionamiento [47, 49].

El aprendizaje puede ser supervisado o no, donde el primero especifica la correcta salida para cada patrón de entradas, mientras que en el segundo la red neuronal explora las relaciones entre los patrones y aprende a categorizar las entradas [48].

## 4.2. Sistema Difuso

### 4.2.1. Generalidades

Aparte de la red neuronal, otra técnica inteligente mundialmente implementada es conocida como sistema difuso la cual aplica sentencias condicionales tal cual un cerebro humano las generaría. El objetivo de todo sistema que utilice una lógica difusa es describir los grados de membresía de los enunciados de salida (dados por una serie de reglas) en términos de los de entrada. Los sistemas difusos manejan datos incompletos o imprecisos en aplicaciones que incluyen función de aproximación, clasificación/agrupamiento, control y predicción.

Ejemplos de dichas aplicaciones abarcan modelado de la dinámica de la vegetación, estimación de las propiedades hidráulicas del suelo, modelado de hábitat idóneo para macroinvertebrados, evaluación del hábitat idóneo para bosques riverños, modelado de terrenos para pesca, identificación de condiciones ecológicas en una laguna, identificación de derrames de petróleo por imágenes satelitales, control de tratamiento de aguas negras, combinaciones de predicción de abundancia y escases de lluvia, predicción de la erosión del suelo, evaluación del riesgo ambiental de la descarga de residuos de perforación, estimación de riesgos de incendio, predicción de riesgo de enfermedades y predicción de sequía regional [48].

### 4.2.2. Sentencias difusas y funciones de membresía

Las reglas difusas *if-then* (si-entonces) son expresiones de la forma *if A then B*, donde A y B son etiquetas de conjuntos difusos caracterizados por funciones de membresía adecuadas. La fuerza de este sistema es la capacidad de capturar los modos imprecisos del razonamiento, por ejemplo:

*If* la presión es alta, *then* el volumen es pequeño

donde *presión* y *volumen* son variables lingüísticas, *alta* y *pequeño* son valores lingüísticos caracterizados por las conocidas *funciones de membresía*. Estas funciones, así como las funciones de activación para las redes neuronales, representan el comportamiento de las entradas de entre varios tipos (triangular, trapezoidal, gaussiana, etc.) permitiendo transformar el valor lingüístico o etiqueta en una magnitud cuantitativa. La elección de la función óptima es facilitada al conocer la velocidad de cambio de la variable siendo una triangular o trapezoidal las más rápidas al tener sólo 2 y 3 pendientes de cambio respectivamente; sin embargo, para una variable con un proceso más lento (temperatura) es recomendable trabajar con una curva mas suave como la gaussiana, aunque no se debe tomar como una regla obligatoria. La Tabla 4.2 muestra las funciones más comunes.

Otra forma de regla difusa *if-then* es la llamada Takagi-Sugeno en la cual sólo la premisa de la sentencia difusa está declarada de manera lingüística.

*If* la velocidad es alta, *then* la fuerza es  $= k * (velocidad)^2$

Como se puede apreciar, la parte de la izquierda sigue manteniéndose como una etiqueta difusa la cual necesita de las funciones de membresía; sin embargo, la parte consecuente está descrita por una ecuación no difusa en base a la variable velocidad [49, 50].

Tabla 4.2: Funciones de membresía

Tipo	Función	Gráfica
Triangular	$\mu_A(x) = \begin{cases} 0 & \text{si } x \leq a \\ (x-a)/(m-a) & \text{si } x \in (a, m] \\ (b-x)/(b-m) & \text{si } x \in (m, b] \\ 0 & \text{si } x \geq b \end{cases}$	
Gamma	$\mu_A(x) = \begin{cases} 0 & \text{si } x \leq a \\ 1 - e^{-k(x-a)^2} & \text{si } x \in (a, m] \end{cases}$	
Trapezoidal	$\mu_A(x) = \begin{cases} 0 & \text{si } x \leq a \text{ o } x \geq d \\ (x-a)/(b-a) & \text{si } x \in (a, b] \\ 1 & \text{si } x \in (b, c] \\ (d-x)/(d-c) & \text{si } x \in (c, d] \end{cases}$	
Gaussiana	$\mu_A(x) = e^{-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2}$	
Campana generalizada	$\mu_A(x) = \frac{1}{1 + \left(\frac{x-c}{a}\right)^{2b}}$	

### 4.2.3. Proceso de inferencia difusa

El uso de las reglas difusas permite transformar una idea en una sentencia condicional difusa necesaria para que un sistema de inferencia difusa pueda trabajar. Dicho sistema, básicamente, está compuesto por 5 bloques funcionales como se aprecia en la Figura 4.2.




Figura 4.2: Sistema de inferencia difusa

La base de conocimientos consta tanto de la base de datos (la cual define las funciones de membresía de los conjuntos difusos) como de la base de reglas donde se encuentran las sentencias condicionales *if-then*. Una vez teniendo estos dos bloques, se procede con el razonamiento difuso.

Las variables de entrada son comparadas con las funciones de membresía previamente declaradas para obtener los valores difusos entre 0 y 1. La cantidad de funciones de membresía en las que se divide la variable depende de la cantidad de etiquetas lingüísticas aplicadas (pequeño, mediano, alto). Tomando como ejemplo la sentencia:

*If* la presión es alta, *then* el volumen es pequeño

y suponiendo que la variable *presión* tenga 3 funciones de membresía de tipo trapezoidal debido a su rapidez de cambio; cada una de ellas representa una etiqueta lingüística: bajo (azul), medio (rojo), y alto (amarillo) tal como se ve en la Figura 4.3. Esta ventaja permite abarcar todos los datos posibles y clasificarlos según la necesidad del modelo. Este proceso denotado por el bloque *Interfaz de Fuzificación* transforma la entrada subjetiva a grados que concuerden con los valores lingüísticos.




Figura 4.3: Ejemplo de tres funciones de membresía de tipo trapezoidal.

El bloque *Unidad de Toma de Decisiones* combina tanto la *Base de Conocimientos* como la *Fuzificación* para procesar y generar un resultado estando aún en el dominio difuso. Una vez que el resultado fue obtenido pasa al bloque *Interfaz de Defuzificación* el cual regresa del dominio difuso al lingüístico que permita entender la solución.

#### 4.2.4. Tipos de sistemas difusos

Dependiendo del razonamiento difuso y de las reglas *if-then* empleadas, la mayoría de los sistemas difusos pueden clasificarse en tres tipos como se muestra en la Figura 4.4.

- *Tipo 1*: La salida total es el promedio de los pesos de la salida numérica de cada regla inducida por la fuerza de disparo (el producto o mínimo de los grados de pertenencia relacionados con la premisa) y las funciones de membresía de la salida las cuales deben ser monotónicas.
- *Tipo 2*: La salida difusa es obtenida mediante la operación *max* aplicada a las salidas difusas calificadas (cada una de las cuales es igual al mínimo de las fuerzas de disparo y las funciones de membresía de salida de cada regla). Algunos de los esquemas para seleccionar la salida numérica final son el centroide del área, bisector del área, el criterio del máximo, etcétera.
- *Tipo 3*: Corresponde a las reglas difusas *if-then* de Takagi y Sugeno. La salida de cada regla es la combinación lineal de las variables de entrada mas un término constante y la salida final es el promedio de los pesos de la salida de cada regla.

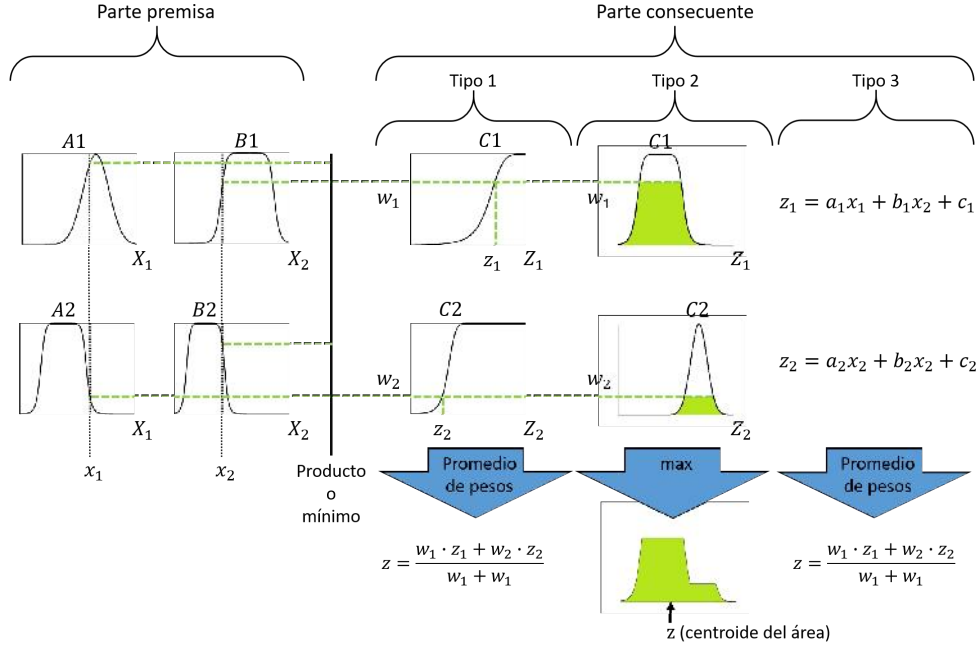


Figura 4.4: Tipos de sistemas difusos.

De acuerdo a la Figura 4.4 la parte de la *premis*a representa a las entradas del sistema donde  $X_1$  (primer entrada) tiene a  $A1$  y  $A2$  como sus funciones de membresía, y a su vez  $B1$  y  $B2$  como las funciones de membresía de la variable  $X_2$  (segunda entrada). Cada regla difusa del sistema está simbolizada por una de las filas, considerando sólo la *premis*a se obtiene:

if  $A1$  and  $B1$ ...  
if  $A2$  and  $B2$ ...

Dependiendo los valores de cada entrada,  $x_1$  y  $x_2$  (líneas punteadas verticales negras), cada función de membresía es intersectada en un punto el cual se especifica a través de las líneas verdes horizontales punteadas. Cada punto de intersección para cada regla difusa es usado para encontrar la fuerza de disparo de dicha regla dado por la Ecuación (4.10)

$$w_i = \text{AndMethod}(F_1(x_1), F_2(x_2)) \quad (4.10)$$

donde  $F_{1,2}(\cdot)$  son las funciones de membresía para las entradas correspondientes. La fuerza de disparo puede ser el producto entre ellas o la selección del mínimo, siendo este último el utilizado en la Figura 4.4. Como se puede apreciar el punto de intersección de  $A1$  fue mayor que el de  $B1$ , sin embargo entre los puntos de intersección de  $A2$  y  $B2$ , es el primero quien tiene el mínimo valor. Por lo anterior, las fuerzas de disparo  $w_1$  y  $w_2$  están dadas por las intersecciones en  $B1$  y  $A2$ .

La salida *Tipo 1* de la parte *consecuente* aplica dos funciones de membresía monotónicas  $C1$  y  $C2$ . Los valores de  $w_1$  y  $w_2$  cortan dichas funciones obteniendo  $z_1$  y  $w_1$  para la primera regla y  $z_2$  y  $w_2$  para la segunda. A partir de los valores obtenidos se aplica la Ecuación (4.11) para obtener la salida total.

$$\text{Salida Final} = \frac{\sum_{i=1}^N w_i z_i}{\sum_{i=1}^N w_i} \quad (4.11)$$

El *Tipo 2* aplica funciones de membresía (no monotónicas) las cuales son intersectadas por su correspondiente fuerza de disparo. El área comprendida bajo  $w_1$  para  $C1$  y  $w_2$  para  $C2$  (áreas verde) es la salida de cada regla difusa, y la unión de ambas la salida total. El valor numérico de la salida total se encuentra, por ejemplo, a través del centroide del área generada.

El *Tipo 3* toma en cuenta la fuerza de disparo de cada regla, pero en lugar de aplicar funciones de membresía se implementa una ecuación lineal (Regla difusa Takagi y Sugeno) incluyendo los valores  $x_1$  y  $x_2$  de la entrada así como de los parámetros  $a_1, b_1, c_1$  para  $z_1$  y  $a_2, b_2, c_2$  para  $z_2$ . La salida numérica se obtiene a partir de la Ecuación (4.11). La Figura 4.5 muestra el proceso general de un sistema difuso Tipo 3.

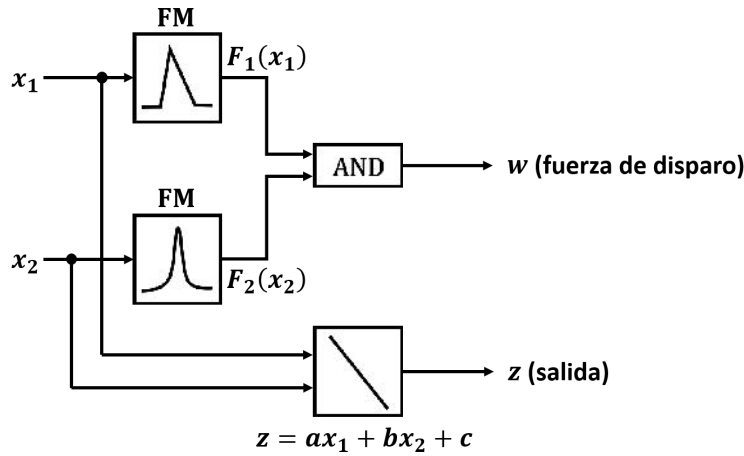


Figura 4.5: Proceso de un sistema difuso Tipo 3.

### 4.3. Red Adaptable basada en Sistemas de Inferencia Difusa

#### 4.3.1. Generalidades

Los sistemas híbridos combinan dos o más técnicas para ganar fortalezas y superar debilidades. Existen 3 tipos principales de sistemas híbridos de acuerdo a cómo son combinadas las técnicas: secuencial, auxiliar y embebido. En un híbrido secuencial, la primer técnica pasa su salida a la entrada de la segunda y de esta manera encontrar la salida general. En un híbrido general, la primer técnica obtiene cierta información de la segunda para generar la salida. En un híbrido embebido, ambas técnicas están contenidas en sí mismas.

El sistema híbrido más común es el llamado neuro-difuso, el cual combina redes neuronales y sistemas difusos. Este método también es conocido como Red Adaptable basada en Sistemas de Inferencia Difusa o ANFIS por sus siglas en inglés. Algunas de las aplicaciones de este sistema híbrido es la predicción del nivel de agua así como la predicción de la vulnerabilidad de aguas subterráneas. Un sistema de inferencia difusa básico consta de dos entradas ( $x_1$  y  $x_2$ ) y una salida ( $z$ ). [48,51].

#### 4.3.2. Descripción de un ANFIS

Suponiendo que sus reglas difusas son del tipo Takagi y Sugeno:

$$\begin{aligned} \text{If } x_1 \text{ is } A_1 \text{ and } x_2 \text{ is } B_1, \text{ then } f_1 &= a_1x_1 + b_1y_1 + c_1 \\ \text{If } x_1 \text{ is } A_2 \text{ and } x_2 \text{ is } B_2, \text{ then } f_2 &= a_2x_2 + b_2y_2 + c_2 \end{aligned}$$

entonces la arquitectura ANFIS equivalente correspondiente al sistema difuso mencionado es como se muestra en la Figura 4.6.

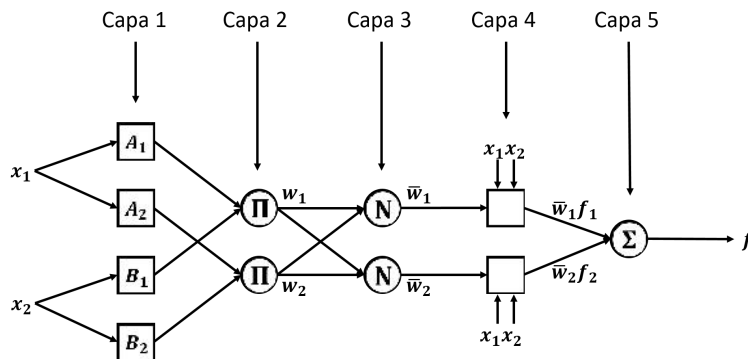


Figura 4.6: Estructura de un ANFIS equivalente a un Tipo 3.

- *Capa 1.*

Cada nodo  $i$  en esta capa es un nodo cuadrado con una función de membresía (Ecuación (4.12)) donde  $x$  es la entrada al nodo  $i$ , y  $A_i$  es la etiqueta lingüística (bajo, alto, etc) asociada con la función.

$$O_i^1 = \mu_{A_i}(x_1) \quad (4.12)$$

- *Capa 2.*

Cada nodo en esta capa es un nodo circular simbolizado por  $\Pi$  el cual implica la multiplicación de las entradas directas para obtener su salida descrita por la Ecuación (4.13). En otras palabras esta capa está conformada por las premisas de cada una de las reglas difusas preestablecidas.

$$w_i = \mu_{A_i}(x_1) \times \mu_{B_i}(x_2), \quad i = 1, 2. \quad (4.13)$$

Cada salida representa la fuerza de disparo de cada regla.

- *Capa 3.*

Cada nodo en esta capa es un nodo circular simbolizado por  $N$ . El  $i$ -ésimo nodo calcula la razón de la  $i$ -ésima fuerza de disparo respecto a la suma de todas las fuerzas de disparo. Por conveniencia, las salidas de esta capa se llaman *fuerzas de disparo normalizada* (Ecuación (4.14)).

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2. \quad (4.14)$$

- *Capa 4.*

Cada nodo  $i$  en esta capa es un nodo cuadrado con la función descrita por la Ecuación (4.15) donde  $\bar{w}_i$  es la salida de la capa 3, y  $\{a_i, b_i, c_i\}$  es el conjunto de parámetros. Los parámetros en esta capa se denominan *parámetros consecuentes* como se ve en la Figura 4.4. Cabe mencionar que a diferencia del sistema difuso, en el ANFIS los parámetros tanto de la premisa como consecuentes se van ajustando durante el entrenamiento.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (a_i x + b_i y + c_i) \quad (4.15)$$

- *Capa 5.*

El único nodo en esta capa es un nodo circular simbolizado por  $\Sigma$  el cual calcula la salida total como la sumatoria de todas las señales de entrada a través de la Ecuación (4.16) la cual es análoga respecto a la Ecuación (4.11).

$$O_1^5 = \text{salida total} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (4.16)$$

### 4.3.3. Entrenamiento

Como se mencionó en la sección 4.1 el entrenamiento híbrido combina el método del gradiente descendente y mínimos cuadrados para encontrar el mejor resultado ajustando los parámetros de las funciones de membresía para la premisa así como los parámetros consecuentes. Cada época de este proceso está compuesta por un paso hacia adelante y un paso hacia atrás.

Dados los valores de los parámetros para la premisa de la Figura 4.6, la salida general puede ser expresada como una combinación lineal de los parámetros consecuentes tal como se describe en la Ecuación (4.17).

$$\begin{aligned} f &= \bar{w}_1 f_1 + \bar{w}_2 f_2 \\ &= (\bar{w}_1 x_1) a_1 + (\bar{w}_1 x_2) b_1 + (\bar{w}_1) c_1 \\ &\quad + (\bar{w}_2 x_1) a_2 + (\bar{w}_2 x_2) b_2 + (\bar{w}_2) c_2 \end{aligned} \quad (4.17)$$

En el paso hacia adelante, se suministran los datos de entrada y las funciones respectivas para calcular las salidas de cada nodo y así poder calcular el error.

Tomando en cuenta la red neuronal por la Ecuación (4.18) donde  $\vec{I}$  es el conjunto de variables de entrada y  $S$  es el conjunto de parámetros; si existe una función  $H$  tal que haga la función compuesta  $H \circ F$  lineal en algunos de los elementos de  $S$ , entonces estos elementos pueden ser identificados a través de mínimos cuadrados. Formalmente, si  $S$  puede ser descompuesto en dos conjuntos  $S_1$  (Conjunto de parámetros de la premisa) y  $S_2$  (Conjunto de parámetros consecuentes) descrito por la Ecuación (4.19) donde  $\oplus$  representa la suma directa tal que  $H \circ F$  es lineal en los elementos de  $S_2$ , entonces se obtiene la Ecuación (4.20) la cual es lineal en los elementos de  $S_2$ .

$$\text{output} = F(\vec{I}, S) \quad (4.18)$$

$$S = S_1 \oplus S_2 \quad (4.19)$$

$$H(\text{output}) = H \circ F(\vec{I}, S) \quad (4.20)$$

Dados valores en  $S_1$ , se aplican datos de entrenamiento  $P$  en la Ecuación (4.20) para obtener la Ecuación (4.21), donde  $\Phi$  (Ecuación (4.22)) es un vector desconocido cuyos elementos son parámetros de  $S_2$ . Siendo  $|S_2| = M$  (número de parámetros lineales), las dimensiones de  $A$ ,  $\Phi$  y  $B$  son  $P \times M$ ,  $M \times 1$  y  $P \times 1$ , respectivamente.

$$A\Phi = B \quad (4.21)$$

$$\Phi = [a_1 \quad b_1 \quad c_1 \quad a_2 \quad b_2 \quad c_2]^T \quad (4.22)$$

Debido a que usualmente  $M$  es mayor que  $P$  el problema tiende a sobredeterminarse, donde la mejor solución para  $\Phi$  es minimizar  $\|A\Phi - B\|^2$  aplicando el estimador de mínimos cuadrados  $\Phi^*$  definido por la Ecuación (4.23).

$$\Phi^* = (A^T A)^{-1} A^T B \quad (4.23)$$

donde  $A^T$  es la matriz transpuesta de  $A$  y  $(A^T A)^{-1} A^T$  es la pseudo-inversa de  $A$ ; sin embargo, esta notación resulta indefinida cuando  $A^T A$  es singular y la carga computacional se incrementa.

En su lugar se emplea un método secuencial o recursivo de mínimos cuadrados más eficiente especialmente cuando  $M$  es pequeña. Siendo  $a_i^T$  la  $i$ -ésima fila de la matriz  $A$  y  $b_i^T$  el  $i$ -ésimo elemento del vector  $B$ ,  $\Phi$  puede calcularse a través de la Ecuación (4.24)

$$\left. \begin{aligned} \Phi_{i+1} &= \Phi_i + S_{i+1} a_{i+1} (b_{i+1}^T - a_{i+1}^T \Phi_i) \\ S_{i+1} &= S_i - \frac{S_i a_{i+1} a_{i+1}^T S_i}{1 + a_{i+1}^T S_i a_{i+1}}, \quad i = 0, 1 \dots, P-1 \end{aligned} \right\} \quad (4.24)$$

donde  $S_{i+1}$  es comúnmente llamada la  $i$ -ésima matriz de covarianza. Las condiciones iniciales para la Ecuación (4.24) son  $\Phi_0 = 0$  y  $S_0 = \gamma I$ , donde  $\gamma$  es un valor positivo grande e  $I$  es la matriz identidad de dimensión  $M \times M$ .

En el paso hacia atrás, las razones de error (Ecuaciones (4.4) y (4.5)) se propagan del extremo de la salida al extremo de la entrada para que los parámetros sean actualizados por el método del gradiente descrito por la Ecuación (4.8) [49, 50].

De esta forma el algoritmo de entrenamiento híbrido puede ser aplicado directamente, en el cual durante el paso hacia adelante las salidas funcionales avanzan hasta la capa 4 (considerando la Figura 4.6) y los parámetros consecuentes son especificados por la estimación de mínimos cuadrados. Durante el paso hacia atrás la razón de error se propaga de regreso resultando en la actualización de los parámetros de la premisa por el gradiente descendente como se describe en la Tabla 4.3.

Tabla 4.3: Pasos del aprendizaje híbrido

-	Paso hacia adelante	Paso hacia atrás
Parámetros de la premisa	Fijos	Gradiente descendente
Parámetros consecuentes	Mínimos cuadrados	Fijos
Señales	Salidas de los nodos	Razones de error

## 4.4. Conclusiones del capítulo

Las RNA son útiles resolviendo problemas con gran cantidad de datos donde los algoritmos o reglas para solucionar el problema son desconocidos o demasiado difíciles de expresar. La estructura de los datos y los cálculos no lineales de la RNA le permiten obtener estimaciones satisfactorias para datos multivariados, procesan información en paralelo y son robustos a errores en los datos; de igual manera, pueden generalizar, encontrando relaciones en datos imperfectos siempre y cuando no existan suficientes neuronas para ajustar incluso dichas imperfecciones. Una de las desventajas de la RNA es su modelo de caja negra el cual impide su uso en problemas que requieran la explicación del proceso. Si una RNA falla al momento de converger al valor necesario, no hay manera de conocer la razón.

El razonamiento humano maneja información vaga o imprecisa. La habilidad de los sistemas difusos para manejar dicha información es una de sus mejores fortalezas sobre las otras tecnologías inteligentes, al igual que son más fáciles de entender y aplicar. Una de las dificultades principales al desarrollar un sistema difuso es determinar las funciones de membresía, aparte de que los sistemas difusos carecen de la habilidad de aprender o tener memoria.

Al combinarse entre sí las RNA con los sistemas difusos, la integración de sus fortalezas le permite al ANFIS ser efectivo, rápido, eficiente, fácil de diseñar, implementar y entender. La necesidad de preparar el sistema difuso se ve reducido por el entrenamiento de la RNA; mientras que los sistemas difusos atenúan el “ruido” del cual sufren las redes neuronales.

Una de las principales fortalezas de un ANFIS sobre la RNA es su capacidad de flexibilidad, permite topologías sencillas para contar con un número de registros restringidos y topologías más complejas para tener bastante información. Aún así, es necesario mencionar que la condición más importante de un ANFIS para que logre o alcance un resultado óptimo es la selección correcta de las entradas. Sin embargo, un sistema híbrido no es perfecto y pueden existir ocasiones en que la combinación resultante retenga las debilidades de ambas técnicas y muy pocas de sus fortalezas; así mismo a menudo es necesaria la integración de un lenguaje en común entre ambas técnicas [48].



# Capítulo 5

## Generación del modelo predictivo inteligente

### 5.1. Selección de las variables meteorológicas

El ANFIS cuenta con muchas ventajas sobre otros métodos de estimación, incluso sobre otros métodos inteligentes como se mencionó en la sección 4.4; sin embargo, para que un sistema neuro-difuso alcance un resultado satisfactorio uno de los requisitos más importantes es la correcta elección de las variables de entrada. Si se intenta modelar, por ejemplo, el comportamiento de la calidad de una llanta de automóvil en el tiempo las variables a considerar podrían ser el material de la llanta, el diseño, sus medidas, la velocidad promedio de rotación o el terreno de desplazamiento. Sin embargo el color de la llanta no altera la calidad de la misma por lo que dicho dato no proporciona ninguna influencia para el modelo, siendo descartado como variable de entrada.

De acuerdo con el capítulo 3.1 las variables meteorológicas, las cuales fueron recolectadas a lo largo de 6 meses de la Universidad de Sonora (UNISON) en la ciudad de Hermosillo, son: radiación solar, temperatura, humedad sensación térmica, punto de rocío, presión atmosférica, velocidad del viento, dirección del viento y la hora del día.

A partir de las variables registradas, se consideraron múltiples estudios sobre modelos inteligentes así como referentes a variables meteorológicas y se implementaron técnicas las cuales ofrecen información sobre la influencia que tiene cada una en la potencia eléctrica fotovoltaica como variable de salida del modelo y así lograr identificar las entradas adecuadas: *correlación, recta de regresión, coeficiente de determinación y gradiente descendente.*

#### 5.1.1. Correlación, recta de regresión y coeficiente de determinación

El análisis de correlación es uno de los métodos estadísticos más usados y reportados en investigaciones científicas y médicas, su representación visual se conoce como gráfica o diagrama de dispersión [52–54]. Es usado para probar o rechazar la existencia de una relación entre dos variables diferentes basado en el coeficiente de correlación de Pearson descrito por la Ecuación (5.1)

$$\rho(U, V) = \frac{E(UV)}{\sigma_U \sigma_V} \quad (5.1)$$

donde  $E(UV)$  es la correlación cruzada entre dos variables aleatorias cuantitativas  $U$  y  $V$  también llamada covarianza,  $\sigma_U$  es la desviación estándar de  $U$  y  $\sigma_V$  es la desviación estándar de  $V$  [55].

Si “ $U$ ” y “ $V$ ” son las dos variables en consideración, una gráfica de dispersión sirve para mostrar la localización de los puntos ( $A, B$ ) en un sistema de coordenadas rectangulares. Si en este diagrama de dispersión todos los puntos parecen encontrarse cerca de una línea recta (línea de regresión o tendencia), a la correlación se le llama lineal. Si “ $V$ ” tiende a aumentar a medida que “ $U$ ” aumenta se dice que la correlación es positiva o directa. Si “ $V$ ” tiende a disminuir a medida que “ $U$ ” aumenta se dice que es una correlación negativa o inversa. Si todos los puntos parecen encontrarse en una curva, esta correspondencia se llama no lineal. Si no parece haber un patrón entre las variables se dice que no hay relación entre ellas [56]. El problema que involucra esta metodología es encontrar la recta o curva que mejor ajuste a la nube de puntos del diagrama y que pueda utilizarse para predecir los valores de salida a partir de los de la entrada.

La Ecuación (5.2) describe la ecuación general de la recta o curva de regresión simple para cualquier grado, donde  $y$  es la salida estimada y  $x$  es la única variable de entrada. Si se busca una recta, la ecuación contará

con los primeros dos términos, si es de grado dos entonces tendrá los primeros 3 términos y así sucesivamente, siempre buscando la curva que mejor ajuste con la nube de puntos.

Ahora bien, para poder implementar la ecuación general es necesario hallar los coeficientes de cada término, esto se logra aplicando algún método de reducción (eliminación de Gauss) a la Ecuación (5.3), donde  $n$  es la cantidad de datos registrados por variable y  $m$  es el grado de la regresión .

$$y = a_0 + a_1x + a_2x^2 + a_3x^3 + \dots + a_mx^m \quad (5.2)$$

$$\left[ \begin{array}{cccccc|c} a_0n & a_1 \sum x_i & a_2 \sum x_i^2 & a_3 \sum x_i^3 & \dots & a_m \sum x_i^m & \sum y_i \\ a_0 \sum x_i & a_1 \sum x_i^2 & a_2 \sum x_i^3 & a_3 \sum x_i^4 & \dots & a_m \sum x_i^{m+1} & \sum x_i y_i \\ a_0 \sum x_i^2 & a_1 \sum x_i^3 & a_2 \sum x_i^4 & a_3 \sum x_i^5 & \dots & a_m \sum x_i^{m+2} & \sum x_i^2 y_i \\ \vdots & \vdots & \vdots & \vdots & & \vdots & \vdots \\ a_0 \sum x_i^m & a_1 \sum x_i^{m+1} & a_2 \sum x_i^{m+2} & a_3 \sum x_i^{m+3} & \dots & a_m \sum x_i^{2m} & \sum x_i^m y_i \end{array} \right] \quad (5.3)$$

Para poder garantizar matemáticamente la curva de regresión que se acaba de encontrar se cuenta con la desviación estandar total y la desviación estándar del estimado descritos por las Ecuaciones (5.4) y (5.5), respectivamente. Si la desviación estándar del estimado es menor que la total, entonces se contempla la curva de regresión como satisfactoria; si no fuera el caso significaría que se debe de cambiar el tipo de grado de la ecuación general.

$$S_y = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n - 1}} \quad (5.4)$$

$$S_{y/x} = \sqrt{\frac{\sum_{i=1}^n (y_i - a_0 - a_1x_i - a_2x_i^2 - a_3x_i^3 - \dots - a_mx_i^m)^2}{n - (m + 1)}} \quad (5.5)$$

El coeficiente de correlación o  $R$ , el cual indica qué tanta relación existe entre la variable independiente y la dependiente, requiere tanto magnitud como dirección ya sea positiva (de 0 a 1) o negativa (de -1 a 0). Si  $R$  se acerca a  $\pm 1$ , la correlación será más fuerte. La correlación no depende de la dirección del signo: una correlación de 0.57 es igual a una de -0.57.

Es importante mencionar que mientras mayor sea el valor absoluto de  $R$ , así será la correlación. El coeficiente de determinación  $R^2$  está definido como el porcentaje de la variación de los valores de la variable dependiente que pueden ser explicados como cambios en la variable independiente. En otras palabras, un coeficiente de determinación  $R^2 = 0,23$  simboliza que el 23% de la variable dependiente está ligado a los cambios de la variable independiente. Por lo tanto, si una correlación de  $R = 0,20$  fuera encontrado entre dos variables, el coeficiente de determinación sería de  $R^2 = 0,04$  por lo que sólo el 4% de la variable dependiente es afectada por las variaciones de la variable independiente [57].


El coeficiente de determinación para este caso se obtiene a través de las Ecuaciones (5.6) y (5.7), donde  $\bar{y}$  es la media de la variable dependiente y  $e$  es el error entre el valor real y el estimado por la regresión. Dichas ecuaciones representan la magnitud del error residual asociado con la variable dependiente antes de la regresión y la suma de errores cuadrados, respectivamente. Ambas ecuaciones son sustituidas en la Ecuación (5.8) para obtener  $R^2$ .

$$S_t = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (5.6)$$


$$S_r = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - a_0 - a_1x_i - a_2x_i^2 - a_3x_i^3 - \dots - a_mx_i^m)^2 \quad (5.7)$$

$$R^2 = \frac{S_t - S_r}{S_t} \quad (5.8)$$


En la Figura 5.1 se muestra cada una de las gráficas de dispersión de las variables meteorológicas recolectadas contra la potencia fotovoltaica obtenida por el inversor. En verde se muestra la nube de puntos entre el valor de la entrada y el de la salida, y en rojo la curva de tendencia o regresión que más se aproxima al comportamiento registrado por la dispersión. Para este procedimiento fue utilizado el software MATLAB<sup>®</sup>.




(a) Radiación solar vs. Potencia fotovoltaica




(b) Temperatura vs. Potencia fotovoltaica




(c) Humedad vs. Potencia fotovoltaica




(d) Sensación térmica vs. Potencia fotovoltaica




(e) Punto de rocío vs. Potencia fotovoltaica




(f) Presión atmosférica vs. Potencia fotovoltaica



(g) Velocidad del viento vs. Potencia fotovoltaica



(h) Dirección del viento vs. Potencia fotovoltaica



(i) Hora vs. Potencia fotovoltaica

Figura 5.1: Diagramas de dispersión. (a) Radiación solar; (b) Temperatura; (c) Humedad; (d) Sensación térmica; (e) Punto de rocío; (f) Presión atmosférica; (g) Velocidad del viento; (h) Dirección del viento; (i) Hora del día

La Tabla 5.1 muestra los valores del coeficiente de determinación para cada variable meteorológica de acuerdo a los diagramas de dispersión de la Figura 5.1. Tomando en cuenta dicha tabla, la radiación solar y la hora son las variables que mayor relación tienen con la potencia fotovoltaica.

Tabla 5.1: Coeficientes de determinación

Variable de entrada	$R^2$
Radiación solar	0.9532
Temperatura	0.1077
Humedad	0.1212
Sensación térmica	0.1070
Punto de rocío	0.0226
Velocidad del viento	0.0140
Dirección del viento	0.0194
Presión atmosférica	0.0222
Hora	0.8098

### 5.1.2. Optimización por Gradiente Descendente

La Optimización por Gradiente Descendente (OGD) está basado en el método de la regresión lineal el cual a través de un parámetro de entrenamiento logra un resultado satisfactorio. Una matriz “ $X$ ” y un vector “ $y$ ” son utilizados para organizar la información recolectada donde el tamaño de la matriz depende tanto de la cantidad de variables de entrada a contemplar (cantidad de columnas) como de la cantidad de datos registrados (cantidad de filas), a su vez la longitud del vector depende únicamente del total de datos registrados. Su consecuente representación se describe en la Ecuación (5.9)

$$X_{OGD} = \begin{bmatrix} x_{11} & x_{12} & x_{13} & \cdots & x_{1k} \\ x_{21} & x_{22} & x_{23} & \cdots & x_{2k} \\ x_{31} & x_{32} & x_{33} & \cdots & x_{3k} \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ x_{n1} & x_{n2} & x_{n3} & \cdots & x_{nk} \end{bmatrix} \quad y_{OGD} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \quad (5.9)$$

El propósito del OGD es encontrar la estimación de la salida real a través de la Ecuación (5.10) donde  $h_\theta(x)$  es la salida estimada,  $x_k$  es la  $k$ -ésima variable de entrada,  $\theta_k$  es el coeficiente característico de cada variable el cual indica la influencia de cada una en la estimación de la salida y  $\varepsilon$  es el error entre el modelo y los datos reales [58].

$$h_\theta(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_k x_k + \varepsilon \quad (5.10)$$

Para lograr el valor mínimo del error, y a diferencia de la regresión lineal la cual utiliza el método de mínimos cuadrados, el OGD encuentra los adecuados coeficientes  $\theta_k$  por derivadas parciales recursivas de la función de costo descrita en la Ecuación (5.11) donde  $m$  es la cantidad total de filas en la matriz “ $X$ ”,  $x^i$  representa la  $i$ -ésima fila de “ $X$ ” y  $y^i$  es el valor de la  $i$ -ésima fila del vector “ $y$ ”. Dicho proceso fue previamente detallado en la sección 4.1.3 a través de las Ecuaciones (4.3) y (4.7), siendo respectivamente las funciones de costo y su derivada para la RNA.

$$J[\theta] = \frac{1}{2m} \sum_{i=1}^m \left( h_\theta(x^{(i)}) - y^{(i)} \right)^2 \quad (5.11)$$

El OGD, denotado por la Ecuación (5.12), busca converger al mínimo de la función de costo a través de su derivada parcial. La rapidez de la convergencia está dado por el valor de  $\eta$  siendo esta la razón de aprendizaje, tal y como se describió en la Ecuación (4.8).

$$\theta_k := \theta_k - \eta \frac{\partial}{\partial \theta_k} J[\theta] \quad (5.12)$$

La Ecuación (5.13) muestra la sustitución de la Ecuación (5.11) en (5.12) la cual debe repetirse a sí misma  $n$  veces hasta que la convergencia se logre.

$$\theta_k := \theta_k - \eta \frac{1}{m} \sum_{i=1}^m \left( h_\theta(x^{(i)}) - y^{(i)} \right) \cdot x_k^{(i)} \quad (5.13)$$

Utilizando los datos meteorológicos previamente establecidos y aplicándoles la Ecuación (5.13), se determina la influencia de cada variable en la potencia fotovoltaica como se muestra en la Tabla 5.2.

Tabla 5.2: Coeficientes por gradiente

Variable de entrada	$\theta_k$
Radiación solar	2.1483
Temperatura	0.0916
Humedad	0.1276
Sensación térmica	0.0915
Punto de rocío	0.0357
Velocidad del viento	0.0128
Dirección del viento	0.3468
Presión atmosférica	0.0994
Hora	0.0015

### 5.1.3. Selección

Tomando en cuenta los valores de influencia obtenidos en las secciones 5.1.1 y 5.1.2, la Tabla 5.3 reúne los resultados de las Tablas 5.1 y 5.2 para poder seleccionar las variables a utilizar en el modelo inteligente. La última columna indica el porcentaje de influencia de cada variable de entrada sobre la salida. Para obtener estos resultados se identifica la variable con los mayores valores registrados, siendo para este caso la radiación solar lo cual es completamente lógico ya que se trata de un SFV y de acuerdo al capítulo 2 el efecto fotovoltaico se logra gracias a esta variable meteorológica. Los valores obtenidos para esta entrada se promedian y se igualan al 100 %, a su vez las demás variables se promedian de igual manera y se dividen respecto al promedio obtenido por la radiación solar, de esta manera el porcentaje que se logra está basado en el máximo obtenido por la radiación solar.

Los resultados más pequeños obtenidos en dicha columna son los correspondientes al punto de rocío y la velocidad del viento, por lo que teóricamente son los que menor influencia tienen sobre la generación de potencia fotovoltaica; sin embargo el viento está clasificado en dos rubros: por su velocidad y su dirección, y aunque el porcentaje de la velocidad fue bajo, el de la dirección fue relativamente alto. De igual manera mucha documentación enfocada en trabajos de estimación y predicción utilizan la velocidad como variable de entrada [59, 60].

Tabla 5.3: Valores de influencia

Variable de entrada	$R^2$	$\theta_k$	Influencia
Radiación solar	0.9532	2.1483	100.00 %
Temperatura	0.1077	0.0916	6.43 %
Humedad	0.1212	0.1276	8.02 %
Sensación térmica	0.1070	0.0915	6.40 %
Punto de rocío	0.0226	0.0357	1.87 %
Velocidad del viento	0.0140	0.0128	0.86 %
Dirección del viento	0.0194	0.3468	11.81 %
Presión atmosférica	0.0222	0.0994	3.92 %
Hora	0.8098	0.0015	26.16 %

Es importante mencionar que, aunque la sensación térmica logró buenos resultados, tanto en el coeficiente de determinación como en el del gradiente sus valores fueron prácticamente los mismos que la temperatura incluso en sus gráficas de dispersión visualizándose en la Figura 5.1(b) y 5.1(d) el mismo comportamiento y nube de puntos.

De acuerdo a lo mencionado anteriormente y en relación a la Tabla 5.3 las variables meteorológicas seleccionadas para el modelo inteligente son: *radiación solar*, *temperatura*, *humedad*, *velocidad del viento*, *dirección del viento*, *presión atmosférica* y *la hora*.

## 5.2. Modelo ANFIS

### 5.2.1. Entrenamiento del sistema

Un modelo ANFIS busca siempre representar fielmente un sistema real del cual no se conoce completa o detalladamente su dinámica interna, tomando en cuenta las entradas y salidas del sistema real y siendo utilizadas para que el modelo ANFIS logre aprender y se comporte lo más similarmente posible al real.

Normalmente un ANFIS sencillo considera las entradas y la salida en un tiempo  $t$  actual. Si se desea generar un modelo que represente el comportamiento de la ecuación que describe la distancia entre dos puntos (Ecuación (5.14)), entonces las variables de entrada serían los valores de las coordenadas  $xy$  del punto  $A$  y del punto  $B$ , mientras que el valor de salida sería la distancia.

$$\overline{AB} = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (5.14)$$

Dicho modelo se comienza a entrenar para que logre aprender que la dinámica interna corresponde a la Ecuación (5.14). Ahora bien, este sistema no sufre alteraciones por el transcurso del tiempo, la medición de la distancia entre  $A$  y  $B$  en un tiempo  $t=1s$  será la misma que en el tiempo  $t=5s$ . Sin embargo, existen sistemas *contínuos* en el tiempo siendo estos los que presentan un patrón definido en sus variables tanto de entrada como de salida, como por ejemplo, el SFV. Tomando en cuenta la Figura 5.1(i) se identifica un patrón analizando cómo se comportan los datos durante el transcurso del día, lo cual es imposible para el caso de la Ecuación (5.14) ya que los futuros valores de coordenadas están definidos por la siguiente:  $x \in R | -\infty \leq x \leq \infty$  y no tienen un orden.

Para este trabajo se necesita que las entradas del modelo estén registradas en un tiempo  $t$  actual y la salida en un tiempo  $t$  futuro, o dicho en otras palabras, la salida del modelo sea la obtenida en un tiempo  $t$  actual mientras que las entradas estén en un tiempo  $t$  anterior. Lo anterior es parte fundamental en el esquema de un modelo predictor el cual es descrito como una estimación aproximada.

La Figura 5.2 muestra el esquema planteado y utilizado para la generación del modelo ANFIS donde  $K$  representa la muestra considerada actualmente. La planta (sistema fotovoltaico real) toma en cuenta las entradas actuales (variables meteorológicas) simbolizadas por  $X(K)$  para obtener la salida actual  $y(K)$  o potencia eléctrica fotovoltaica. El modelo ANFIS, debido a su carácter de predictor, no puede tener las mismas variables que la planta por lo que la entrada  $X(K)$  pasa a través del bloque  $z^{-1}$  el cual toma en cuenta la entrada una vez anterior descrita como  $X(K-1)$  y a su vez la salida  $y(K)$  pasa por  $z^{-2}$  para que sea considerada la salida dos veces anterior descrita como  $y(K-2)$ . Ambas señales son las respectivas entradas del modelo ANFIS mientras que su salida será la potencia eléctrica fotovoltaica actual  $y(K)$ , de esta manera el modelo inteligente tendría teóricamente el siguiente razonamiento: la potencia fotovoltaica dos veces anterior afectada por las variables meteorológicas siguientes resulta en la potencia actual (Ecuación (5.15)).

Una vez que el ANFIS ha sido entrenado completamente, el esquema presentado se modifica para que actúe como autorecursivo como se muestra en la Figura 5.3. La entrada  $y(K-2)$  ya no es tomado directamente de la planta sino de la misma salida del estimador inteligente; y la diferencia resultante entre la potencia obtenida de la planta y la del ANFIS, la cual era utilizada para el entrenamiento, se define como el error del sistema neuro-difuso contra el valor real medido. La Ecuación (5.16) describe el comportamiento matemático del ANFIS en su modalidad de predictor.

$$\text{Potencia } (z^{-2}) \longrightarrow \text{Variables meteorológicas } (z^{-1}) \longrightarrow \text{Potencia } (z) \quad (5.15)$$




Figura 5.2: Esquema de entrenamiento




Figura 5.3: Esquema como predictor

$$\begin{aligned} y(K) &= f(X(K-1), \hat{y}(K-2)) \\ X(K-1) &= x_1(K-1), x_2(K-1), \dots, x_n(K-1) \end{aligned} \quad (5.16)$$

Considerando la Ecuación 5.16, a continuación se muestra la Tabla 5.4 en la cual se declara la nomenclatura implementada en SIMULINK y su simbología general para representar cada variable elegida de ahora en adelante.

Tabla 5.4: Nomenclatura y simbología de las variables contempladas en el modelo.

Variabes	SIMULINK	Simbología
Radiación solar	RAD	$x_1$
Dirección del viento	DV	$x_2$
Humedad	HUM	$x_3$
Presión atmosférica	ATM	$x_4$
Temperatura	TEMP	$x_5$
Velocidad del viento	VV	$x_6$
Hora del día	HR	$x_7$
Potencia eléctrica	POT	$y$

De acuerdo a la sección 5.1.3 se toman en cuenta 7 variables meteorológicas y considerando el esquema predictor se agrega la potencia autorecursiva, teniendo finalmente 8 entradas para el aprendizaje del ANFIS. Durante el entrenamiento, realizado con el software MATLAB<sup>®</sup> R2015a, se utilizó una máquina con procesador CORE i5 de séptima generación y 6 meses de datos tomando lecturas cada 5 minutos durante el día, obteniendo aproximadamente 16300 datos en total por cada variable considerada.

Lo anterior plantea un problema en el tiempo de cómputo necesario para entrenar el sistema neuro-difuso debido a la cantidad de memoria RAM que el procesador requiere. A mayor cantidad de datos de entrenamiento, mayor deberá ser la memoria RAM necesaria. Ahora bien, aunque la totalidad de datos y de variables de entrada influyen directamente en el tiempo de cómputo, también lo son la cantidad de funciones de membresía que se definen para cada variable. Estas funciones, tal como se mencionó en la sección 4.2.3, son las responsables de la generación de las reglas difusas del ANFIS.

Si se toma como ejemplo a dos variables de entrada y cada una con dos funciones de membresía se generan 4 reglas difusas, el ANFIS durante el entrenamiento ajusta los parámetros de las funciones correspondientes así como los pesos entre neuronas haciendo uso de todos los datos recabados para ambas variables.

Teniendo en cuenta que son 8 variables de entrada en total y suponiendo que a cada variable se le declara con 2 funciones de membresía únicamente (lo cual no permite una estimación ideal), se tendrían en total  $2^8 = 256$  reglas difusas. Ahora bien, si se quisiera precisar la estimación y aumentar a 3 funciones de membresía para cada variable se tendrían en total  $3^8 = 6561$  reglas difusas. Es importante mencionar que para que el entrenamiento logre su objetivo, debe repetirse a sí mismo varias veces mientras va minimizando el error entre la estimación y lo real; concluyendo que el procesador debe soportar la cantidad de variables de entrada, cantidad de datos por variable, cantidad de funciones de membresía para cada variable y cantidad de repeticiones que tendrá el ANFIS al entrenar.

Experimentalmente, la máquina utilizada tardó más de un día completo en terminar el entrenamiento con 1000 repeticiones para el primer caso, alcanzando una estimación poco satisfactoria; mientras que para el segundo caso la máquina no soportó el procesamiento y se apagó.

Para resolver este problema, se optó por distribuir las variables de entrada en diferentes ANFIS en lugar de en uno solo y al final los sistemas resultantes alimentan a uno final [61]. De esta manera los primeros ANFIS tienen pocas variables de entrada lo cual minimiza considerablemente la cantidad de reglas difusas y por consiguiente el tiempo total de procesamiento. El objetivo del último ANFIS es reunir los resultados de todos los anteriores y utilizarlos para obtener la estimación final la cual dependerá de todas las variables de entrada originales.

La Figura 5.4 muestra la arquitectura elegida teniendo 3 ANFIS iniciales: el primero con la radiación solar, dirección del viento y humedad como sus entradas; el segundo con la presión atmosférica y temperatura y el tercero con la velocidad del viento, la hora y la potencia (la cual será necesaria para la autorecursividad). Las salidas de dichos ANFIS alimentan a un cuarto quien genera la estimación final y se compara con la potencia fotovoltaica real. Este arreglo permite declararle más funciones de membresía al sistema y más repeticiones de entrenamiento. Las Ecuaciones (5.17)-(5.20) describen las funciones implementadas para entrenar cada ANFIS.

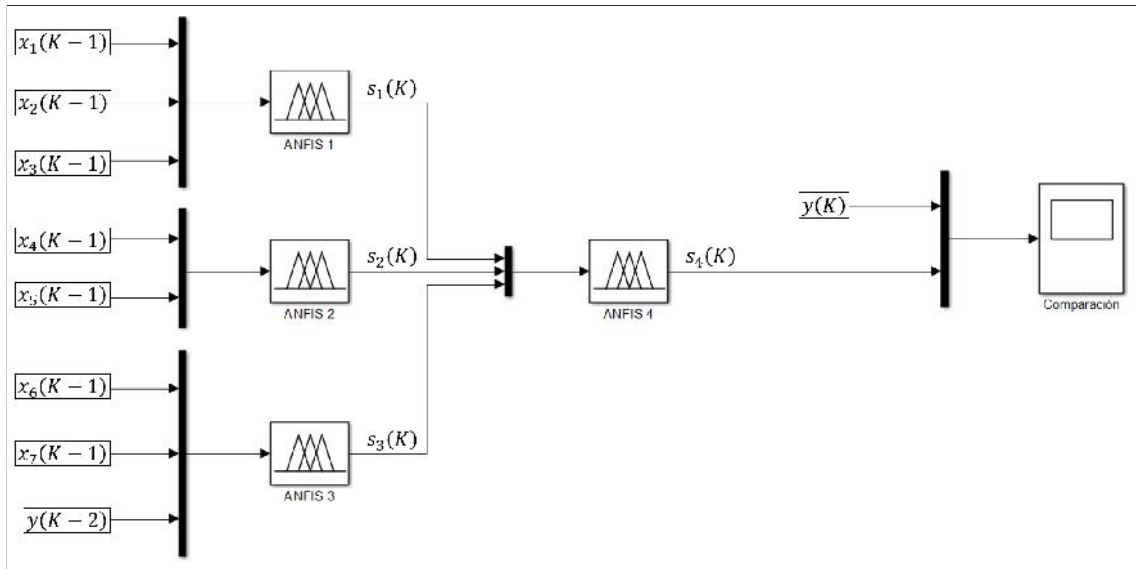


Figura 5.4: Arquitectura final para el entrenamiento del sistema neurodifuso.


$$s_1(K) = f(x_1(K-1), x_2(K-1), x_3(K-1), y(K)) \quad (5.17)$$

$$s_2(K) = f(x_4(K-1), x_5(K-1), y(K)) \quad (5.18)$$


$$s_3(K) = f(x_6(K-1), x_7(K-1), y(K-2), y(K)) \quad (5.19)$$

$$s_4(K) = f(s_1(K), s_2(K), s_3(K), y(K)) \quad (5.20)$$


La Figura 5.5 ilustra los datos de entrada de cada variable seleccionada para el entrenamiento del modelo.



(a)



(b)



(c)



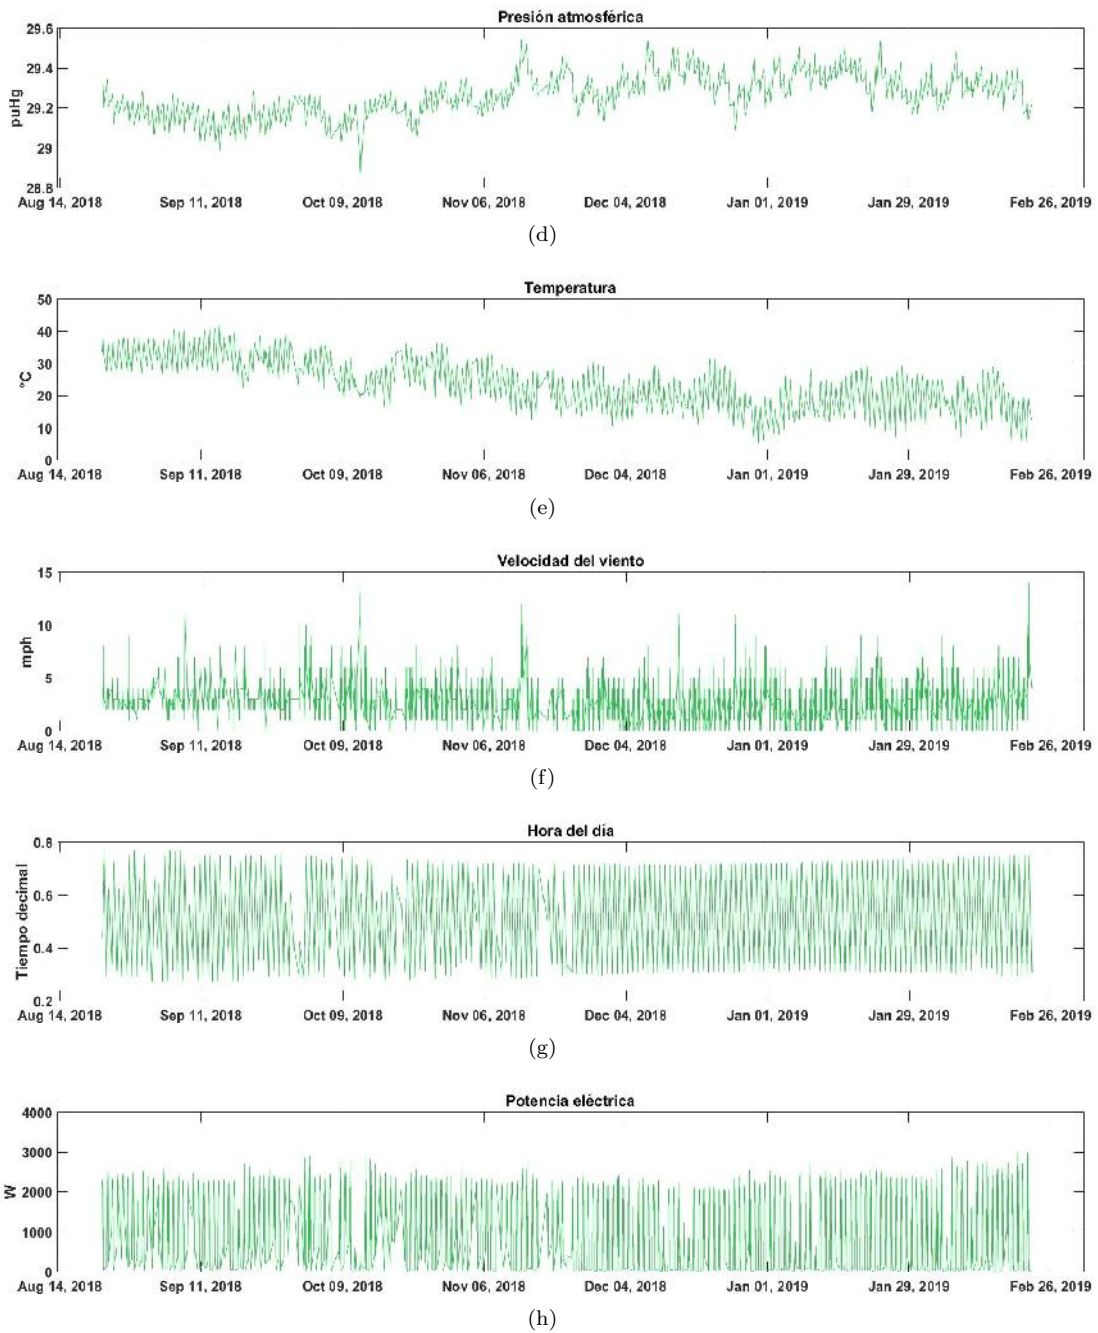


Figura 5.5: Datos de entrenamiento. (a) Radiación solar; (b) Dirección del viento; (c) Humedad; (d) Presión atmosférica; (e) Temperatura; (f) Velocidad del viento; (g) Hora del día; (h) Potencia eléctrica.

Con la finalidad de encontrar los ANFIS que mejor desempeño alcancen en su estimación, fueron necesarios diversos ensayos con diferentes tipos y cantidades de funciones de membresía para cada variable, obteniéndose distintos valores de parámetros después del entrenamiento en general. A continuación se detallan las características de los modelos inteligentes que lograron los mejores desempeños.

### Características del ANFIS 1.

La Figura 5.6 muestra gráficamente las funciones de membresía después del entrenamiento para cada variable de entrada del ANFIS 1, siendo 4 de tipo triangular para la radiación solar, 3 de tipo triangular para la dirección del viento medida en grados y 3 de tipo trapezoidal para la humedad. Los parámetros correspondientes a cada una de ellas están nombrados y especificados detalladamente en la Tabla 5.5. Debido a la cantidad de funciones de membresía por cada variable, se tienen 36 reglas difusas las cuales se definen puntualmente en la Tabla 5.6; finalmente, la Tabla 5.7 describe cada uno de los parámetros para las funciones lineales del tipo Takagi-Sugeno, tal como se mencionan en la sección 4.3.2.

Para el trabajo presentado y de acuerdo con la cantidad variables de entrada, la función Takagi-Sugeno que describe la salida del ANFIS 1 está dada por la Ecuación (5.21), donde  $x_1$ ,  $x_2$  y  $x_3$  corresponden a los datos respectivos de las variables meteorológicas.

$$FM1 = a_1x_1 + b_1x_2 + c_1x_3 + d_1 \quad (5.21)$$

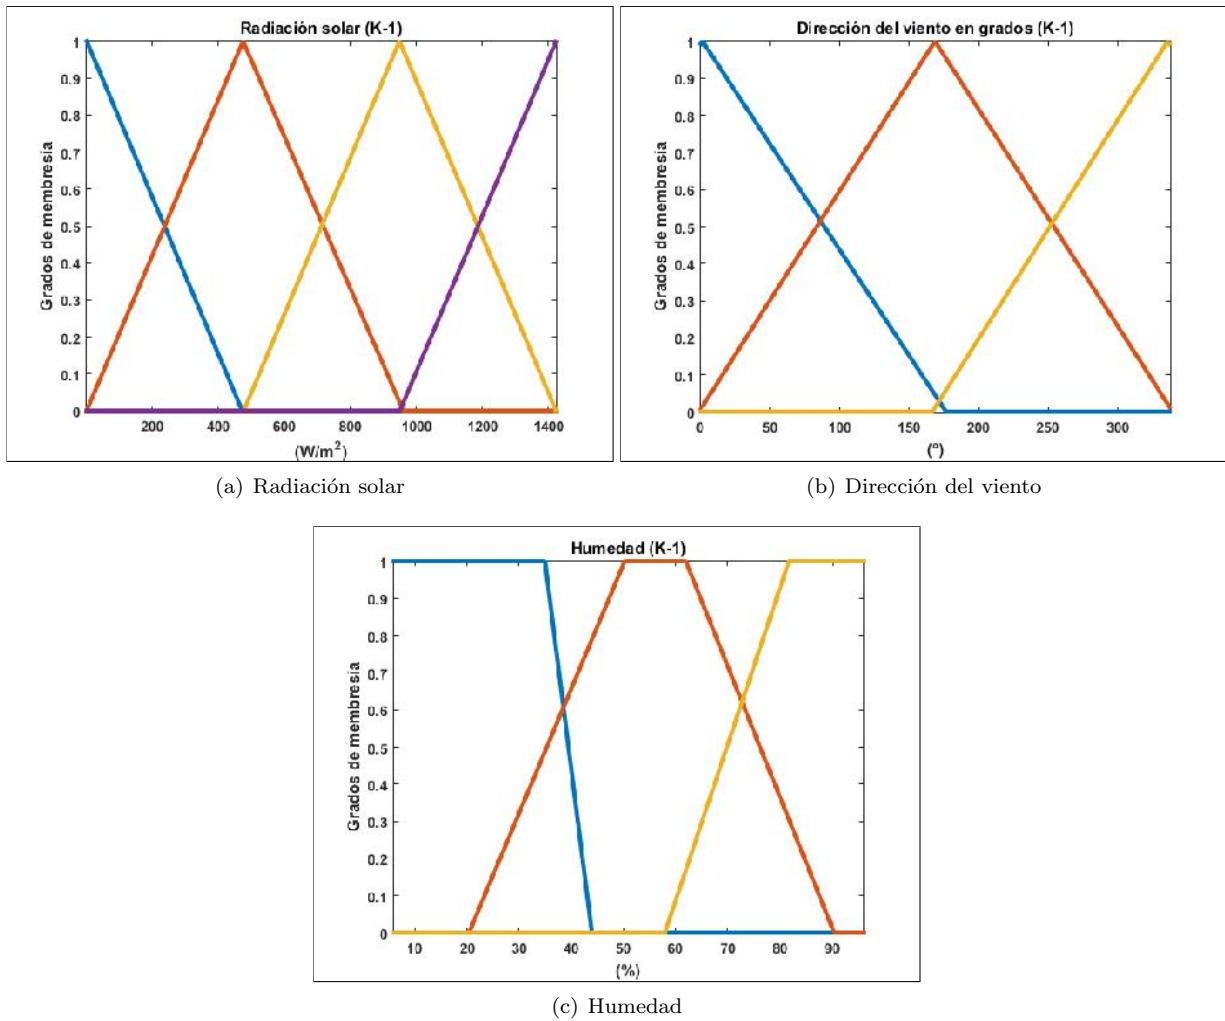


Figura 5.6: Funciones de membresía del ANFIS 1 después del entrenamiento: (a) Radiación solar tipo triangular, (b) Dirección del viento en grados tipo triangular, (c) Humedad tipo trapezoidal.

Tabla 5.5: Parámetros de las funciones de membresía del ANFIS 1 despues del entrenamiento.

Radiación (K-1)				Dirección del viento en grados (K-1)				Humedad (K-1)				
FM	Parámetros			FM	Parámetros			FM	Parámetros			
Triangular	a	b	c	Triangular	a	b	c	Trapezoidal	a	b	c	d
RAD1	-474	0.3237	471.6	DV1	-168.8	1.247	176.5	HUM1	-25.5	-7.5	35	44
RAD2	-0.02736	474.1	959.7	DV2	-1.279	168.4	339.3	HUM2	20.41	50.29	62	90.45
RAD3	476.1	947.8	1423	DV3	166.4	335.7	506.3	HUM3	58	81.77	109.5	127.5
RAD4	949	1423	1897									

Tabla 5.6: Reglas difusas para el ANFIS 1.

<i>if</i>	RAD1	<i>and</i>	DV1	<i>and</i>	HUM1,	<i>then</i>	FM1
<i>if</i>	RAD1	<i>and</i>	DV1	<i>and</i>	HUM2,	<i>then</i>	FM2
<i>if</i>	RAD1	<i>and</i>	DV1	<i>and</i>	HUM3,	<i>then</i>	FM3
<i>if</i>	RAD1	<i>and</i>	DV2	<i>and</i>	HUM1,	<i>then</i>	FM4
<i>if</i>	RAD1	<i>and</i>	DV2	<i>and</i>	HUM2,	<i>then</i>	FM5
<i>if</i>	RAD1	<i>and</i>	DV2	<i>and</i>	HUM3,	<i>then</i>	FM6
<i>if</i>	RAD1	<i>and</i>	DV3	<i>and</i>	HUM1,	<i>then</i>	FM7
<i>if</i>	RAD1	<i>and</i>	DV3	<i>and</i>	HUM2,	<i>then</i>	FM8
<i>if</i>	RAD1	<i>and</i>	DV3	<i>and</i>	HUM3,	<i>then</i>	FM9
<i>if</i>	RAD2	<i>and</i>	DV1	<i>and</i>	HUM1,	<i>then</i>	FM10
<i>if</i>	RAD2	<i>and</i>	DV1	<i>and</i>	HUM2,	<i>then</i>	FM11
<i>if</i>	RAD2	<i>and</i>	DV1	<i>and</i>	HUM3,	<i>then</i>	FM12
<i>if</i>	RAD2	<i>and</i>	DV2	<i>and</i>	HUM1,	<i>then</i>	FM13
<i>if</i>	RAD2	<i>and</i>	DV2	<i>and</i>	HUM2,	<i>then</i>	FM14
<i>if</i>	RAD2	<i>and</i>	DV2	<i>and</i>	HUM3,	<i>then</i>	FM15
<i>if</i>	RAD2	<i>and</i>	DV3	<i>and</i>	HUM1,	<i>then</i>	FM16
<i>if</i>	RAD2	<i>and</i>	DV3	<i>and</i>	HUM2,	<i>then</i>	FM17
<i>if</i>	RAD2	<i>and</i>	DV3	<i>and</i>	HUM3,	<i>then</i>	FM18
<i>if</i>	RAD3	<i>and</i>	DV1	<i>and</i>	HUM1,	<i>then</i>	FM19
<i>if</i>	RAD3	<i>and</i>	DV1	<i>and</i>	HUM2,	<i>then</i>	FM20
<i>if</i>	RAD3	<i>and</i>	DV1	<i>and</i>	HUM3,	<i>then</i>	FM21
<i>if</i>	RAD3	<i>and</i>	DV2	<i>and</i>	HUM1,	<i>then</i>	FM22
<i>if</i>	RAD3	<i>and</i>	DV2	<i>and</i>	HUM2,	<i>then</i>	FM23
<i>if</i>	RAD3	<i>and</i>	DV2	<i>and</i>	HUM3,	<i>then</i>	FM24
<i>if</i>	RAD3	<i>and</i>	DV3	<i>and</i>	HUM1,	<i>then</i>	FM25
<i>if</i>	RAD3	<i>and</i>	DV3	<i>and</i>	HUM2,	<i>then</i>	FM26
<i>if</i>	RAD3	<i>and</i>	DV3	<i>and</i>	HUM3,	<i>then</i>	FM27
<i>if</i>	RAD4	<i>and</i>	DV1	<i>and</i>	HUM1,	<i>then</i>	FM28
<i>if</i>	RAD4	<i>and</i>	DV1	<i>and</i>	HUM2,	<i>then</i>	FM29
<i>if</i>	RAD4	<i>and</i>	DV1	<i>and</i>	HUM3,	<i>then</i>	FM30
<i>if</i>	RAD4	<i>and</i>	DV2	<i>and</i>	HUM1,	<i>then</i>	FM31
<i>if</i>	RAD4	<i>and</i>	DV2	<i>and</i>	HUM2,	<i>then</i>	FM32
<i>if</i>	RAD4	<i>and</i>	DV2	<i>and</i>	HUM3,	<i>then</i>	FM33
<i>if</i>	RAD4	<i>and</i>	DV3	<i>and</i>	HUM1,	<i>then</i>	FM34
<i>if</i>	RAD4	<i>and</i>	DV3	<i>and</i>	HUM2,	<i>then</i>	FM35
<i>if</i>	RAD4	<i>and</i>	DV3	<i>and</i>	HUM3,	<i>then</i>	FM36

Tabla 5.7: Parámetros lineales tipo Takagi-Sugeno para la salida del ANFIS 1 despues del entrenamiento.

		Potencia (K)			
FM	Parámetros				
Lineal	a	b	c	d	
FM1	-4.644	29.37	-2.257	-185	
FM2	-19.52	-15.2	-35.1	2135	
FM3	-58.58	4.982	-57.58	5655	
FM4	8.892	25.48	32.6	-4874	
FM5	3.471	-9.057	44.75	-518.3	
FM6	75.08	14.23	70.25	-8537	
FM7	17.28	24.43	-38.01	-7490	
FM8	-49.85	-2.689	-54.02	3858	
FM9	235	18.19	-78.3	1025	
FM10	-4.977	28.27	7.188	3298	
FM11	-18.03	-3.386	-0.6138	$1.02 \times 10^4$	
FM12	-58.89	-15.74	-27.32	$3.02 \times 10^4$	
FM13	9.261	24.69	-12.09	-7216	
FM14	1.122	4.508	-3.209	309.7	
FM15	73.58	-38.19	-1.23	$-2.80 \times 10^4$	
FM16	19.33	26.87	42.85	$-1.79 \times 10^4$	
FM17	-50.49	9.083	72.08	$1.85 \times 10^4$	
FM18	233	-54.08	70.79	$-9.88 \times 10^4$	
FM19	-4.977	-0.8872	5.955	6869	
FM20	-19	-2.313	37.89	$1.87 \times 10^4$	
FM21	-55.19	-48.32	208.6	$3.96 \times 10^4$	
FM22	9.025	-3.848	6.348	-6150	
FM23	2.016	-1.058	-15.8	1206	
FM24	67.26	-70.82	-116.3	$-4.36 \times 10^4$	
FM25	19.07	-4.472	-17.59	$-1.43 \times 10^4$	
FM26	-51.81	2.752	-41.01	$5.28 \times 10^4$	
FM27	226.4	-75.56	-194.3	$-1.76 \times 10^5$	
FM28	-5.255	-153.6	-34.36	$1.11 \times 10^4$	
FM29	-15.44	35.01	-15.33	$2.49 \times 10^4$	
FM30	90.25	1961	-2647	-6592	
FM31	-8.413	-157.4	-30.38	$3.59 \times 10^4$	
FM32	0.1416	46.69	-84.17	-2473	
FM33	-8.719	675.9	3117	$-3.53 \times 10^5$	
FM34	18.14	-153.5	81.89	$2.83 \times 10^4$	
FM35	-50.65	45.06	-23.67	$5.92 \times 10^4$	
FM36	180.3	350.4	-3000	$-1.91 \times 10^5$	

### Características del ANFIS 2.

La Figura 5.7 muestra gráficamente las funciones de membresía del ANFIS 2, siendo 3 de tipo triangular para para la presión atmosférica y 3 de tipo gaussiana para la temperatura debido a su comportamiento lento. Los parámetros de dichas funciones están descritas en la Tabla 5.8. Contemplando 3 funciones de membresía por cada variable de entrada se consiguen 9 reglas difusas las cuales se presentan en la Tabla 5.9. De igual manera la Tabla 5.10 contiene las funciones Takagi-Sugeno de la salida del ANFIS 2.

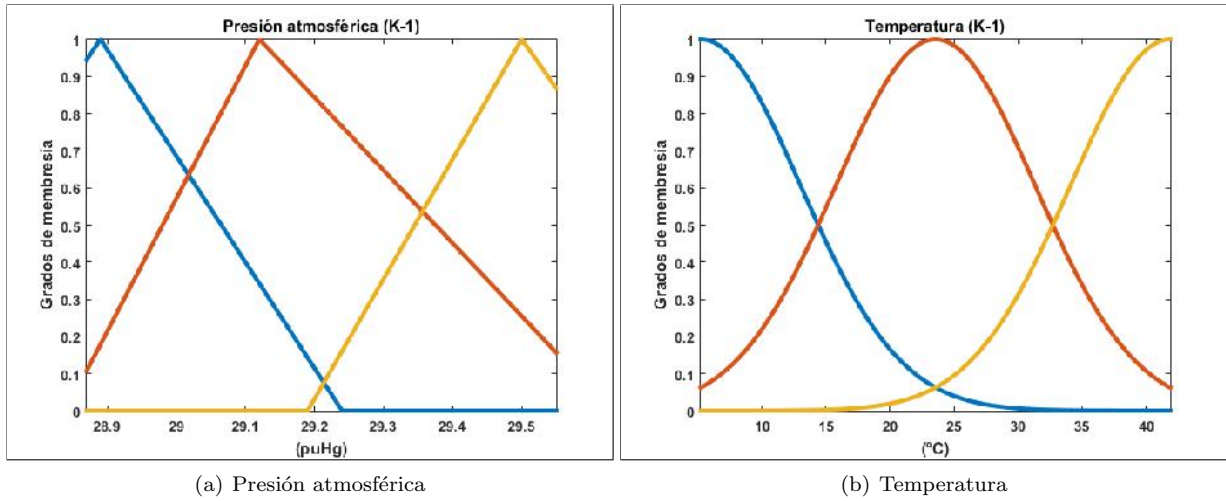


Figura 5.7: Funciones de membresía del ANFIS 2 después del entrenamiento: (a) Presión atmosférica tipo triangular, (b) Temperatura tipo Gauss.

Tabla 5.8: Parámetros de las funciones de membresía del ANFIS 2 después del entrenamiento.

Presión atmosférica (K-1)				Temperatura (K-1)		
FM	Parámetros			FM	Parámetros	
Triangular	a	b	c	Gauss	$\sigma$	c
ATM1	28.53	28.89	29.24	TEMP1	7.794	5.231
ATM2	28.84	29.12	29.63	TEMP2	7.781	23.56
ATM3	29.19	29.5	29.88	TEMP3	7.786	41.89

Tabla 5.9: Reglas difusas para el ANFIS 2.

<i>if</i>	ATM1	<i>and</i>	TEMP1,	<i>then</i>	FM1
<i>if</i>	ATM1	<i>and</i>	TEMP2,	<i>then</i>	FM2
<i>if</i>	ATM1	<i>and</i>	TEMP3,	<i>then</i>	FM3
<i>if</i>	ATM2	<i>and</i>	TEMP1,	<i>then</i>	FM4
<i>if</i>	ATM2	<i>and</i>	TEMP2,	<i>then</i>	FM5
<i>if</i>	ATM2	<i>and</i>	TEMP3,	<i>then</i>	FM6
<i>if</i>	ATM3	<i>and</i>	TEMP1,	<i>then</i>	FM7
<i>if</i>	ATM3	<i>and</i>	TEMP2,	<i>then</i>	FM8
<i>if</i>	ATM3	<i>and</i>	TEMP3,	<i>then</i>	FM9

Tabla 5.10: Parámetros lineales tipo Takagi-Sugeno para la salida del ANFIS 2 después del entrenamiento.

Potencia (K)			
FM	Parámetros		
Lineal	a	b	c
FM1	$3.90 \times 10^4$	879.7	$-1.11 \times 10^6$
FM2	-53.65	699.7	$-1.70 \times 10^4$
FM3	$5.29 \times 10^4$	1316	$-1.58 \times 10^6$
FM4	$1.26 \times 10^5$	495.3	$-3.68 \times 10^6$
FM5	$-1.61 \times 10^4$	24.6	$4.70 \times 10^5$
FM6	$2.08 \times 10^4$	-335.7	$-5.95 \times 10^5$
FM7	$5.57 \times 10^4$	-299.8	$-1.65 \times 10^6$
FM8	-4730	158.1	$1.40 \times 10^5$
FM9	$-3.47 \times 10^4$	276.6	$1.01 \times 10^6$

### Características del ANFIS 3.

La Figura 5.8 muestra las funciones de membresía del ANFIS 3, siendo 3 de tipo triangular para la velocidad del viento, 3 de tipo triangular para la hora del día y 4 de tipo gaussiana para la potencia. Los parámetros de dichas funciones están descritas en la Tabla 5.11. Contemplando 3, 3 y 4 funciones de membresía por cada variable de entrada, respectivamente, se consiguen 36 reglas difusas las cuales se presentan en la Tabla 5.12. De igual manera la Tabla 5.13 contiene las funciones Takagi-Sugeno de la salida del ANFIS 3.

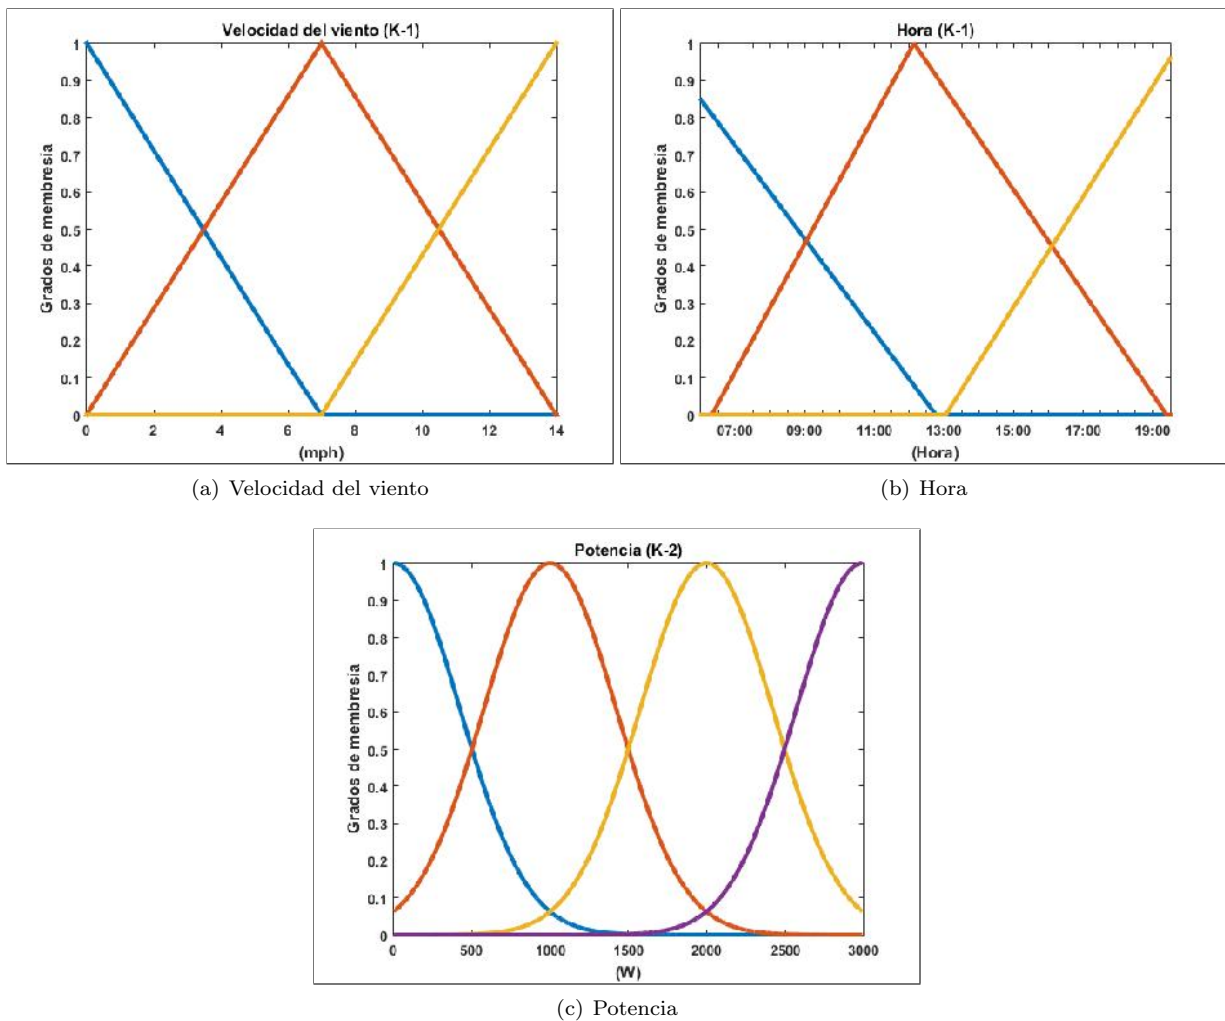


Figura 5.8: Funciones de membresía del ANFIS 3 después del entrenamiento: (a) Velocidad del viento tipo triangular, (b) Hora del día tipo triangular, (c) Potencia tipo Gauss.

Tabla 5.11: Parámetros de las funciones de membresía del ANFIS 3 después del entrenamiento.

Velocidad del viento (K-1)				Hora (K-1)				Potencia (K-2)		
FM	Parámetros			FM	Parámetros			FM	Parámetros	
Triangular	a	b	c	Triangular	a	b	c	Gauss	$\sigma$	c
VV1	-7	0.0004911	6.945	HR1	0.02083	0.2257	0.5208	POT1	424	5.586
VV2	-0.0004223	7	14	HR2	0.2821	0.4974	0.7664	POT2	424	1004
VV3	7	14	21	HR3	0.5312	0.7804	1.021	POT3	424	2003
								POT4	424	3001

Tabla 5.12: Reglas difusas para el ANFIS 3.

<i>if</i>	VV1	<i>and</i>	HR1	<i>and</i>	POT1,	<i>then</i>	FM1
<i>if</i>	VV1	<i>and</i>	HR1	<i>and</i>	POT2,	<i>then</i>	FM2
<i>if</i>	VV1	<i>and</i>	HR1	<i>and</i>	POT3,	<i>then</i>	FM3
<i>if</i>	VV1	<i>and</i>	HR1	<i>and</i>	POT4,	<i>then</i>	FM4
<i>if</i>	VV1	<i>and</i>	HR2	<i>and</i>	POT1,	<i>then</i>	FM5
<i>if</i>	VV1	<i>and</i>	HR2	<i>and</i>	POT2,	<i>then</i>	FM6
<i>if</i>	VV1	<i>and</i>	HR2	<i>and</i>	POT3,	<i>then</i>	FM7
<i>if</i>	VV1	<i>and</i>	HR2	<i>and</i>	POT4,	<i>then</i>	FM8
<i>if</i>	VV1	<i>and</i>	HR3	<i>and</i>	POT1,	<i>then</i>	FM9
<i>if</i>	VV1	<i>and</i>	HR3	<i>and</i>	POT2,	<i>then</i>	FM10
<i>if</i>	VV1	<i>and</i>	HR3	<i>and</i>	POT3,	<i>then</i>	FM11
<i>if</i>	VV1	<i>and</i>	HR3	<i>and</i>	POT4,	<i>then</i>	FM12
<i>if</i>	VV2	<i>and</i>	HR1	<i>and</i>	POT1,	<i>then</i>	FM13
<i>if</i>	VV2	<i>and</i>	HR1	<i>and</i>	POT2,	<i>then</i>	FM14
<i>if</i>	VV2	<i>and</i>	HR1	<i>and</i>	POT3,	<i>then</i>	FM15
<i>if</i>	VV2	<i>and</i>	HR1	<i>and</i>	POT4,	<i>then</i>	FM16
<i>if</i>	VV2	<i>and</i>	HR2	<i>and</i>	POT1,	<i>then</i>	FM17
<i>if</i>	VV2	<i>and</i>	HR2	<i>and</i>	POT2,	<i>then</i>	FM18
<i>if</i>	VV2	<i>and</i>	HR2	<i>and</i>	POT3,	<i>then</i>	FM19
<i>if</i>	VV2	<i>and</i>	HR2	<i>and</i>	POT4,	<i>then</i>	FM20
<i>if</i>	VV2	<i>and</i>	HR3	<i>and</i>	POT1,	<i>then</i>	FM21
<i>if</i>	VV2	<i>and</i>	HR3	<i>and</i>	POT2,	<i>then</i>	FM22
<i>if</i>	VV2	<i>and</i>	HR3	<i>and</i>	POT3,	<i>then</i>	FM23
<i>if</i>	VV2	<i>and</i>	HR3	<i>and</i>	POT4,	<i>then</i>	FM24
<i>if</i>	VV3	<i>and</i>	HR1	<i>and</i>	POT1,	<i>then</i>	FM25
<i>if</i>	VV3	<i>and</i>	HR1	<i>and</i>	POT2,	<i>then</i>	FM26
<i>if</i>	VV3	<i>and</i>	HR1	<i>and</i>	POT3,	<i>then</i>	FM27
<i>if</i>	VV3	<i>and</i>	HR1	<i>and</i>	POT4,	<i>then</i>	FM28
<i>if</i>	VV3	<i>and</i>	HR2	<i>and</i>	POT1,	<i>then</i>	FM29
<i>if</i>	VV3	<i>and</i>	HR2	<i>and</i>	POT2,	<i>then</i>	FM30
<i>if</i>	VV3	<i>and</i>	HR2	<i>and</i>	POT3,	<i>then</i>	FM31
<i>if</i>	VV3	<i>and</i>	HR2	<i>and</i>	POT4,	<i>then</i>	FM32
<i>if</i>	VV3	<i>and</i>	HR3	<i>and</i>	POT1,	<i>then</i>	FM33
<i>if</i>	VV3	<i>and</i>	HR3	<i>and</i>	POT2,	<i>then</i>	FM34
<i>if</i>	VV3	<i>and</i>	HR3	<i>and</i>	POT3,	<i>then</i>	FM35
<i>if</i>	VV3	<i>and</i>	HR3	<i>and</i>	POT4,	<i>then</i>	FM36

Tabla 5.13: Parámetros lineales tipo Takagi-Sugeno para la salida del ANFIS 3 después del entrenamiento.

FM	Potencia (K)			
	Parámetros			
Lineal	a	b	c	d
FM1	2892	$-4.35 \times 10^4$	1.07	$1.24 \times 10^4$
FM2	-403.3	$9.75 \times 10^4$	-0.6207	$-2.67 \times 10^4$
FM3	1867	3382	-1.688	2484
FM4	$1.00 \times 10^4$	$5.38 \times 10^4$	-11.08	$1.10 \times 10^4$
FM5	$1.41 \times 10^4$	$-2.76 \times 10^4$	-1.168	$1.51 \times 10^4$
FM6	-7701	$6.09 \times 10^4$	0.9249	$-3.17 \times 10^4$
FM7	5613	-5432	1.06	2722
FM8	-7626	$1.80 \times 10^4$	1.306	$-1.06 \times 10^4$
FM9	-2970	$-2.52 \times 10^4$	1.004	$1.92 \times 10^4$
FM10	6321	$5.04 \times 10^4$	-0.01612	$-3.89 \times 10^4$
FM11	$-1.03 \times 10^4$	-4691	0.5764	4149
FM12	$1.17 \times 10^4$	$-2.60 \times 10^4$	-3.045	$2.20 \times 10^4$
FM13	2888	$1.39 \times 10^5$	1.751	$-5.91 \times 10^4$
FM14	-407.3	$-1.28 \times 10^5$	2.831	$3.79 \times 10^4$
FM15	1819	$3.63 \times 10^4$	2.96	$-2.76 \times 10^4$
FM16	$1.01 \times 10^4$	$-1.70 \times 10^4$	17.56	$-1.14 \times 10^5$
FM17	$1.41 \times 10^4$	$9.16 \times 10^4$	3.562	$-1.47 \times 10^5$
FM18	-7721	$-8.12 \times 10^4$	0.7136	$9.73 \times 10^4$
FM19	5654	$1.33 \times 10^4$	1.033	$-4.67 \times 10^4$
FM20	-7720	$-2.09 \times 10^4$	-1.567	$7.13 \times 10^4$
FM21	-3031	$8.88 \times 10^4$	0.7372	$-4.67 \times 10^4$
FM22	6377	$-8.44 \times 10^4$	1.195	$1.90 \times 10^4$
FM23	$-1.03 \times 10^4$	-8565	1.359	$7.46 \times 10^4$
FM24	$1.24 \times 10^4$	$-4.49 \times 10^4$	10.71	$-8.57 \times 10^4$
FM25	3464	6594	7.861	$-4.75 \times 10^4$
FM26	-7.72	$1.06 \times 10^4$	8.929	-8742
FM27	1946	$-3.48 \times 10^4$	33.74	$-6.24 \times 10^4$
FM28	9984	$2.12 \times 10^5$	-50.9	$-1.13 \times 10^5$
FM29	$1.38 \times 10^4$	$3.14 \times 10^4$	6.583	$-2.09 \times 10^5$
FM30	-8150	$-1.00 \times 10^4$	4.71	$1.12 \times 10^5$
FM31	5731	$1.24 \times 10^5$	-15.14	$-1.11 \times 10^5$
FM32	-7682	$-2.87 \times 10^4$	-9.154	$1.56 \times 10^5$
FM33	-2605	$6.02 \times 10^4$	-0.5737	-6849
FM34	6713	$-6.52 \times 10^4$	-3.079	$-4.24 \times 10^4$
FM35	$-1.05 \times 10^4$	$3.18 \times 10^5$	14.2	$-1.04 \times 10^5$
FM36	$1.14 \times 10^4$	$-9.83 \times 10^4$	-108.1	$1.81 \times 10^5$

#### Características del ANFIS 4.

El ANFIS 4 se encarga de recolectar las estimaciones de los primeros 3 ANFIS quienes en la Figura 5.9 muestran tener 3 funciones de membresía de tipo gaussiana cada una y sus respectivos parámetros descritos en la Tabla 5.14. La cantidad de reglas difusas asciende a 27 las cuales se presentan en la Tabla 5.15 y las funciones Takagi-Sugeno de salida se describen en la Tabla 5.16.



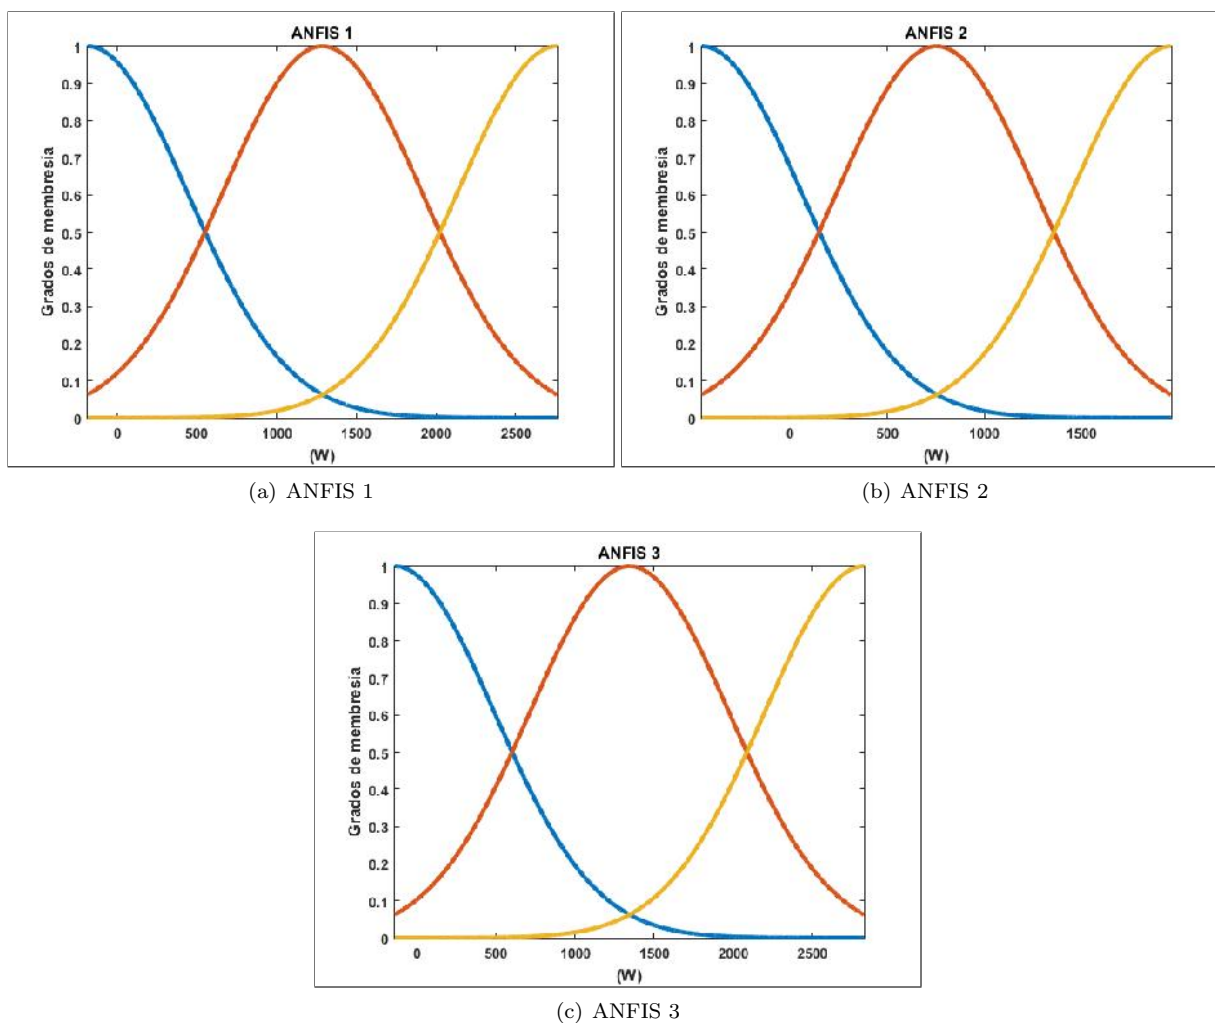


Figura 5.9: Funciones de membresía del ANFIS 4 después del entrenamiento: (a) ANFIS 1 tipo Gauss, (b) ANFIS 2 tipo Gauss, (c) ANFIS 3 tipo Gauss.

Tabla 5.14: Parámetros de las funciones de membresía del ANFIS 4 después del entrenamiento.

	ANFIS 1		ANFIS 2			ANFIS 3		
FM	Parámetros		FM	Parámetros		FM	Parámetros	
Gauss	$\sigma$	$c$	Gauss	$\sigma$	$c$	Gauss	$\sigma$	$c$
A11	626.1	-187.3	A21	516	-460.6	A31	631.3	-142.1
A12	625.8	1286	A22	515.2	752	A32	631	1344
A13	625.9	2760	A23	514.9	1965	A33	630.6	2830

Tabla 5.15: Reglas difusas para el ANFIS 4.

<i>if</i>	A11	<i>and</i>	A21	<i>and</i>	A31,	<i>then</i>	FM1
<i>if</i>	A11	<i>and</i>	A21	<i>and</i>	A32,	<i>then</i>	FM2
<i>if</i>	A11	<i>and</i>	A21	<i>and</i>	A33,	<i>then</i>	FM3
<i>if</i>	A11	<i>and</i>	A22	<i>and</i>	A31,	<i>then</i>	FM4
<i>if</i>	A11	<i>and</i>	A22	<i>and</i>	A32,	<i>then</i>	FM5
<i>if</i>	A11	<i>and</i>	A22	<i>and</i>	A33,	<i>then</i>	FM6
<i>if</i>	A11	<i>and</i>	A23	<i>and</i>	A31,	<i>then</i>	FM7
<i>if</i>	A11	<i>and</i>	A23	<i>and</i>	A32,	<i>then</i>	FM8
<i>if</i>	A11	<i>and</i>	A23	<i>and</i>	A33,	<i>then</i>	FM9
<i>if</i>	A12	<i>and</i>	A21	<i>and</i>	A31,	<i>then</i>	FM10
<i>if</i>	A12	<i>and</i>	A21	<i>and</i>	A32,	<i>then</i>	FM11
<i>if</i>	A12	<i>and</i>	A21	<i>and</i>	A33,	<i>then</i>	FM12
<i>if</i>	A12	<i>and</i>	A22	<i>and</i>	A31,	<i>then</i>	FM13
<i>if</i>	A12	<i>and</i>	A22	<i>and</i>	A32,	<i>then</i>	FM14
<i>if</i>	A12	<i>and</i>	A22	<i>and</i>	A33,	<i>then</i>	FM15
<i>if</i>	A12	<i>and</i>	A23	<i>and</i>	A31,	<i>then</i>	FM16
<i>if</i>	A12	<i>and</i>	A23	<i>and</i>	A32,	<i>then</i>	FM17
<i>if</i>	A12	<i>and</i>	A23	<i>and</i>	A33,	<i>then</i>	FM18
<i>if</i>	A13	<i>and</i>	A21	<i>and</i>	A31,	<i>then</i>	FM19
<i>if</i>	A13	<i>and</i>	A21	<i>and</i>	A32,	<i>then</i>	FM20
<i>if</i>	A13	<i>and</i>	A21	<i>and</i>	A33,	<i>then</i>	FM21
<i>if</i>	A13	<i>and</i>	A22	<i>and</i>	A31,	<i>then</i>	FM22
<i>if</i>	A13	<i>and</i>	A22	<i>and</i>	A32,	<i>then</i>	FM23
<i>if</i>	A13	<i>and</i>	A22	<i>and</i>	A33,	<i>then</i>	FM24
<i>if</i>	A13	<i>and</i>	A23	<i>and</i>	A31,	<i>then</i>	FM25
<i>if</i>	A13	<i>and</i>	A23	<i>and</i>	A32,	<i>then</i>	FM26
<i>if</i>	A13	<i>and</i>	A23	<i>and</i>	A33,	<i>then</i>	FM27

Tabla 5.16: Parámetros lineales tipo Takagi-Sugeno para la salida del ANFIS 4 después del entrenamiento.

Potencia (K)				
FM	Parámetros			
Lineal	a	b	c	d
FM1	0.2483	0.8226	-6.061	-575.3
FM2	17.55	-4.908	-36.35	$2.36 \times 10^4$
FM3	877.7	-308.7	-172.5	$1.14 \times 10^5$
FM4	-1.072	0.6756	0.9078	-823.3
FM5	0.4908	-2.665	1.826	1897
FM6	-8.582	8.904	7.168	$-1.22 \times 10^4$
FM7	1.131	0.4862	2.701	-169.7
FM8	2.12	-1.93	2.929	362.6
FM9	2.583	13.53	-0.2677	$-2.67 \times 10^4$
FM10	20.04	-0.3015	-20.31	$-1.18 \times 10^4$
FM11	-14.28	-7.604	-0.7769	$1.12 \times 10^4$
FM12	110	287	-167.3	$5.49 \times 10^4$
FM13	-2.102	-0.7236	0.5229	2746
FM14	1.839	-0.5258	-0.2314	75.78
FM15	-0.7647	10.59	0.03547	-9912
FM16	4.011	-0.7631	0.8781	-1915
FM17	0.3993	-0.1501	0.5419	100.4
FM18	0.02369	1.273	-0.1697	-800.8
FM19	-564.9	564.7	962.5	$7.17 \times 10^4$
FM20	-34.08	-436.2	17.92	$2.10 \times 10^5$
FM21	17.73	519.8	-21.73	$-2.99 \times 10^5$
FM22	1.654	46.37	-26.33	$-3.15 \times 10^4$
FM23	5.2	-16.68	-1.896	$1.48 \times 10^4$
FM24	-1.346	12.45	1.71	$-1.41 \times 10^4$
FM25	25.84	28.54	6.556	$-1.14 \times 10^5$
FM26	-1.472	-4.052	0.7064	$1.21 \times 10^4$
FM27	0.8026	3.316	-0.1622	-5578

## 5.2.2. Resultados

Una vez realizado el entrenamiento con los datos de 6 meses contemplados y de acuerdo a la Figura 5.4, se procede a implementar el modelo en el programa SIMULINK de MATLAB<sup>®</sup> y su consecuente simulación. Para poder realizar la simulación del sistema es necesario contemplar datos diferentes a los utilizados durante el entrenamiento, estos datos son conocidos como “datos frescos” y para este trabajo se contemplan del 22 de febrero al 17 de mayo del 2019.

La Figura 5.10 presenta el resultado estimado basado en la arquitectura de entrenamiento. Se puede observar que se generan ciertos picos de potencia indeseados a lo largo de la estimación sobrepasando el máximo y el mínimo real. Estos picos son físicamente imposibles debido a que la planta fotovoltaica, como se mencionó en la sección 2.1.4, tiene una generación máxima de 3.1kW; mientras que ante la ausencia de radiación solar (turno nocturno) el inversor se desconecta evitando la generación de potencia alguna.




Figura 5.10: Resultado del sistema neuro-difuso implementado.

Debido a estas consideraciones se aplicó un acotamiento entre 0 W y 3100 W en la simulación para acercar el sistema neuro-difuso aun más al comportamiento real. Dicho acotamiento, en caso de existir un pico indeseado, toma en consideración la potencia fotovoltaica estimada anterior al momento del pico permitiendo que el sistema ANFIS vuelva a estimar el resultado antes del error fuera de rango y se ajuste de manera satisfactoria automáticamente. Las Figuras 5.11 y 5.12 muestran su implementación en la simulación y el proceso contemplado para el acotamiento mencionado, respectivamente. Finalmente, la Figura 5.13 despliega el resultado obtenido.

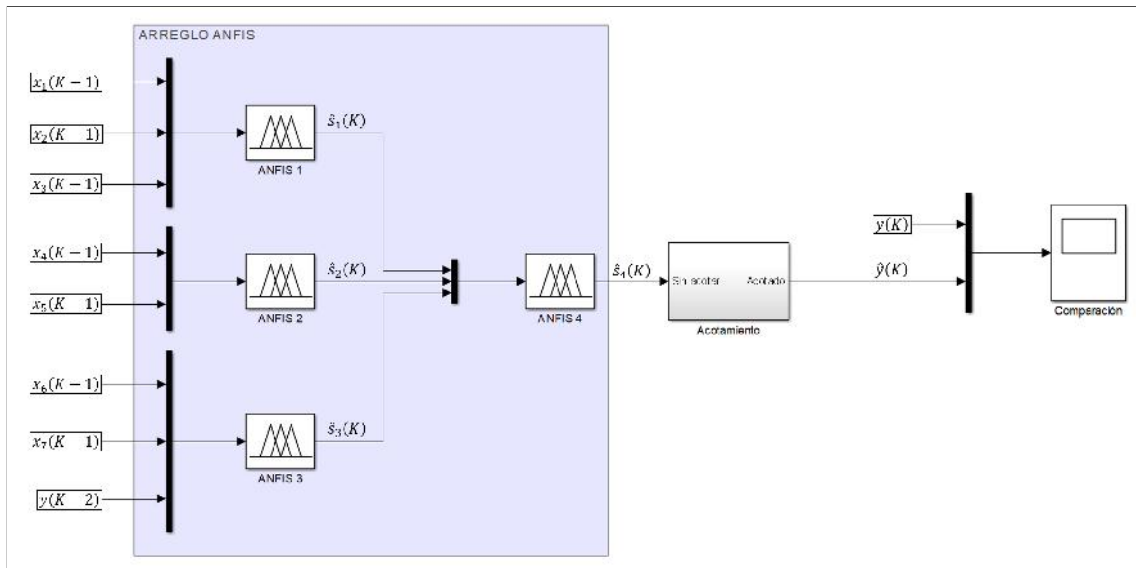


Figura 5.11: Arreglo ANFIS con salida acotada.




Figura 5.12: Diagrama de flujo del acotamiento.




Figura 5.13: Resultado del sistema neuro-difuso implementado con acotamiento.

Finalmente se aplica la recursividad en el sistema y así retroalimentar la salida como la tercer entrada del ANFIS 3. A través de esto el sistema neuro-difuso ya no dependerá de los valores de potencia de la planta (recopilados), sino de los resultados que él mismo genere; teniendo como únicas entradas externas las variables meteorológicas del sitio.

Cabe mencionar que antes de simular el sistema se requiere una última modificación al mismo. Debido a que la potencia como entrada está considerada con un retardo respecto a las entradas restantes, es necesario implementar condiciones iniciales o de lo contrario el ANFIS estimará un valor aleatorio para comenzar.

La primer estimación que se realiza toma en cuenta las 8 entradas en total, sin embargo, la entrada de potencia es tomada de la salida generada, misma que no puede obtenerse sin el dato de la potencia de entrada mencionada. Para ello la condición inicial indica que:

$$\hat{y}(K) = y(K) \quad (5.22)$$

$$\hat{y}(K + 1) = y(K + 1) \quad (5.23)$$

Lo anterior explica que para las dos primeras estimaciones, a causa del retardo de segundo orden, el valor de potencia de entrada será considerado como el de la planta; consecuentemente se toma en cuenta el generado por la estimación gracias a la recursividad. La Figura 5.14 presenta el esquema de simulación final implementado en SIMULINK, y la Figura 5.15 muestra el resultado obtenido. Finalmente, las funciones de estimación representativas para cada ANFIS se detallan en las Ecuaciones (5.24)-(5.27).

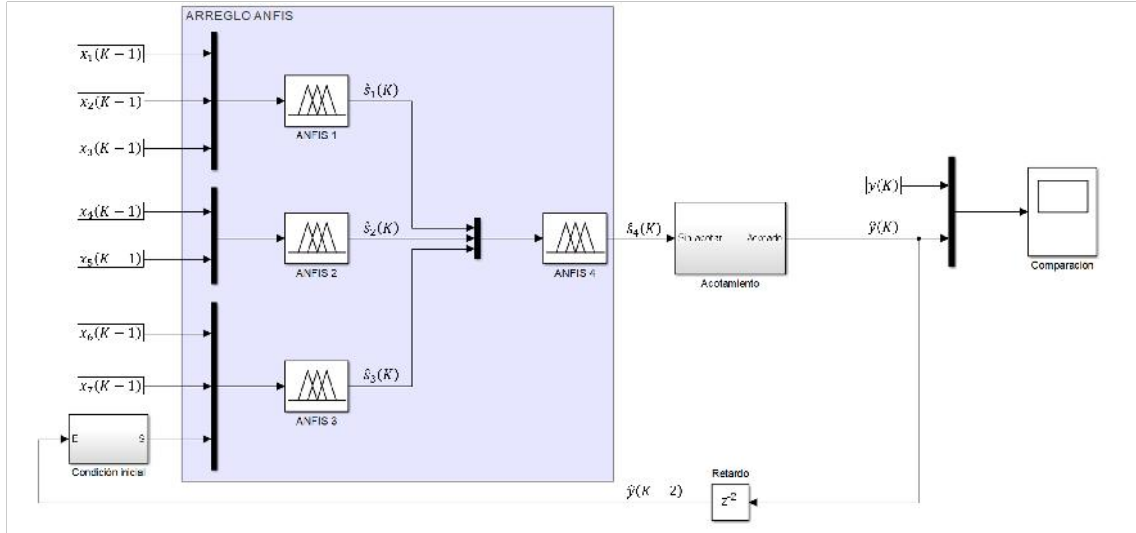


Figura 5.14: Arreglo ANFIS autorecursivo.




Figura 5.15: Resultado del sistema neuro-difuso implementado autorecursivo con acotamiento.

$$\hat{s}_1(K) = f(x_1(K-1), x_2(K-1), x_3(K-1)) \quad (5.24)$$

$$\hat{s}_2(K) = f(x_4(K-1), x_5(K-1)) \quad (5.25)$$

$$\hat{s}_3(K) = f(x_6(K-1), x_7(K-1), \hat{y}(K-2)) \quad (5.26)$$

$$\hat{s}_4(K) = f(\hat{s}_1(K), \hat{s}_2(K), \hat{s}_3(K)) \quad (5.27)$$

### 5.3. Conclusiones del capítulo

Se logra observar un resultado satisfactorio en el cual el comportamiento del sistema neuro-difuso es muy cercano al real, incluso para los días donde la potencia fotovoltaica no fue la ideal, teniendo crestas por debajo del valor promedio y comportamientos estocásticos. De igual manera es posible identificar un incremento en ciertos picos ubicados en los valles de cada día estimado, esto se debe a las características de los datos recopilados para dichas horas.

Es bien sabido que aunque el calendario utilizado hoy en día permite a las personas organizar tiempos y fechas durante todo el año, no es completamente exacto; razón por la cual existen métodos de ajuste del mismo tales como la aplicación del año bisiesto y la implementación del horario de verano. Este estudio no está exento de dichos fenómenos, si bien la cantidad de datos no abarca más del año, sí es afectado por el recorrido del amanecer y anochecer con el transcurso de los días. Este suceso ocasiona que los datos registrados al comienzo y final de cada día recopilado no estén exactamente sincronizados y vayan cambiando con el paso del tiempo, *e.g.*, para el mes de septiembre el amanecer tiene lugar a las 7:15 am aproximadamente, sin embargo en mayo está ubicado a las 6:00 am aproximadamente.

El cambio de dicho horario a través del tiempo genera un ligero error en el sistema neuro-difuso al momento de su entrenamiento. Debido a que el entrenamiento del sistema fue realizado para un periodo de tiempo previo al mostrado en los resultados, del 22 de agosto de 2018 al 22 de febrero del 2019, el ANFIS entrenó para un cierto rango de horarios de amanecer y anochecer. La Figura 5.15 detalla que para los días estimados más cercanos al periodo de entrenamiento (febrero y marzo) se aprecia un comportamiento casi ideal, sin embargo, para los días sucesivos comienza a generarse un pequeño error el cual se puede apreciar en los picos antes mencionados durante cada valle diario y que con el paso del tiempo incrementa.

# Capítulo 6

## Validación

Para poder determinar el grado de satisfacción del resultado obtenido es necesario demostrar que el método empleado fue el óptimo para dicha tarea, esto se logra realizando una comparación de la técnica elegida y descrita en la sección 4.3.2 contra procedimientos estadísticos los cuales puedan obtener dicha estimación usando las mismas características y condiciones. De igual manera, se debe aplicar un método que indique la cercanía de la estimación obtenida con respecto al comportamiento real. La Figura 5.15, aunque gráficamente muestre un desempeño exitoso, no es posible tomarla como técnica decisiva. Debido a lo mencionado anteriormente, se emplea la Regresión Lineal Múltiple (RLM) y el OGD, descrito en la sección 5.1.2, como métodos estadísticos de comparación; así mismo, se emplea el coeficiente de determinación mencionado en la sección 5.1.1 y varios errores comúnmente utilizados en estimaciones por sistemas inteligentes para determinar su precisión.

### 6.1. Comparación contra métodos estadísticos

La relación que existe entre una o más variables de entrada y la salida se representa por la conocida “regresión lineal”. Dependiendo de la cantidad de variables de entrada, la regresión puede ser simple o múltiple [26, 29, 62, 63]. El propósito de la RLM, así como en el OGD, es hallar una estimación de la salida real a través de una expresión matemática lineal la cual contemple toda la información registrada, como se muestra en la Ecuación 6.1

$$h_{\beta}(x) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \epsilon \quad (6.1)$$

donde  $y$  es la salida estimada,  $x_k$  es la  $k$ -ésima variable de entrada,  $\beta_k$  es el coeficiente característico de cada variable y  $\epsilon$  es el error entre el modelo y los datos reales.

Debido a que OGD está basado en RLM, la matriz  $X$  y el vector  $y$  de la Ecuación 5.9 son utilizadas para obtener los valores  $\beta$  requeridos, con la única diferencia que la matriz  $X$  debe comenzar con una columna de unos adicional a las  $y$  descritas, tal como se muestra en la Ecuación 6.2.

$$X_{RLM} = \begin{bmatrix} 1 & x_{11} & x_{12} & x_{13} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & x_{23} & \dots & x_{2k} \\ 1 & x_{31} & x_{32} & x_{33} & \dots & x_{3k} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & x_{n3} & \dots & x_{nk} \end{bmatrix} \quad y_{RLM} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \quad (6.2)$$

Una vez que dichos arreglos han sido realizados se emplea la Ecuación (6.3), la cual emplea la pseudoinversa de la matriz  $X$ , para encontrar los parámetros o coeficientes requeridos y estos sean consecuentemente sustituidos en la Ecuación (6.1).

$$\beta = (X'X)^{-1} (X'y) \quad (6.3)$$

Considerando la Tabla 5.4 y de manera análoga con el modelo inteligente, la Ecuación (6.2) se convierte en la Ecuación (6.4).

$$X_{OGD} = [ 1 \quad x_i (K-1) \quad y (K-2) ] \quad y_{RLM} = [ y (K) ] \quad i = [1, 2, \dots, 7] \quad (6.4)$$

La Tabla 6.1 muestra los resultados de los parámetros encontrados a través de ambos métodos estadísticos.



Tabla 6.1: Parámetros estadísticos obtenidos.

Variable	$k$	$\beta$	$\theta$
	0	$3.645255 \times 10^{-7}$	0.0006
$x_1(K-1)$	1	$-3.143725 \times 10^{-10}$	0.4371
$x_2(K-1)$	2	$-6.259351 \times 10^{-10}$	0.0607
$x_3(K-1)$	3	$1.000449 \times 10^{-8}$	0.0294
$x_4(K-1)$	4	$-4.199137 \times 10^{-8}$	0.0177
$x_5(K-1)$	5	$-4.577245 \times 10^{-10}$	0.0119
$x_6(K-1)$	6	$-1.365379 \times 10^{-10}$	0.0017
$x_7(K-1)$	7	$-1.109584 \times 10^{-9}$	0.0002
$y(K-2)$	8	$6.430412 \times 10^{-13}$	0.7918

Las Ecuaciones (6.5) y (6.6) describen las estimaciones obtenidas por cada método estadístico para los mismos datos utilizados en el modelo inteligente. Si bien ambas técnicas tuvieron solución numérica, es importante resaltar que las magnitudes calculadas para  $\beta$  son muy próximas a cero, por lo que la estimación resultante es prácticamente nula. Considerando lo anterior, a continuación se presenta la comparación entre la estimación obtenida a través del OGD y ANFIS usando los datos de entrenamiento (Figura 6.1) y los datos frescos (Figura 6.2).

$$\begin{aligned}
 \hat{y}_{RLM}(K) &= h_{\beta}(x_i(K-1), y(K-2)) \\
 &= 3,645255 \times 10^{-7} - 3,143725 \times 10^{-10}x_1 - 6,259351 \times 10^{-10}x_2 \\
 &\quad + 1,000449 \times 10^{-8}x_3 - 4,199137 \times 10^{-8}x_4 - 4,577245 \times 10^{-10}x_5 \\
 &\quad - 1,365379 \times 10^{-10}x_6 - 1,109584 \times 10^{-9}x_7 + 6,430412 \times 10^{-13}x_8
 \end{aligned} \tag{6.5}$$

$$\begin{aligned}
 \hat{y}_{OGD}(K) &= h_{\theta}(x_i(K-1), y(K-2)) \\
 &= 0,0006 + 0,4371x_1 + 0,0607x_2 + 0,0294x_3 \\
 &\quad + 0,0177x_4 + 0,0119x_5 + 0,0017x_6 + 0,0002x_7 + 0,7918x_8
 \end{aligned} \tag{6.6}$$

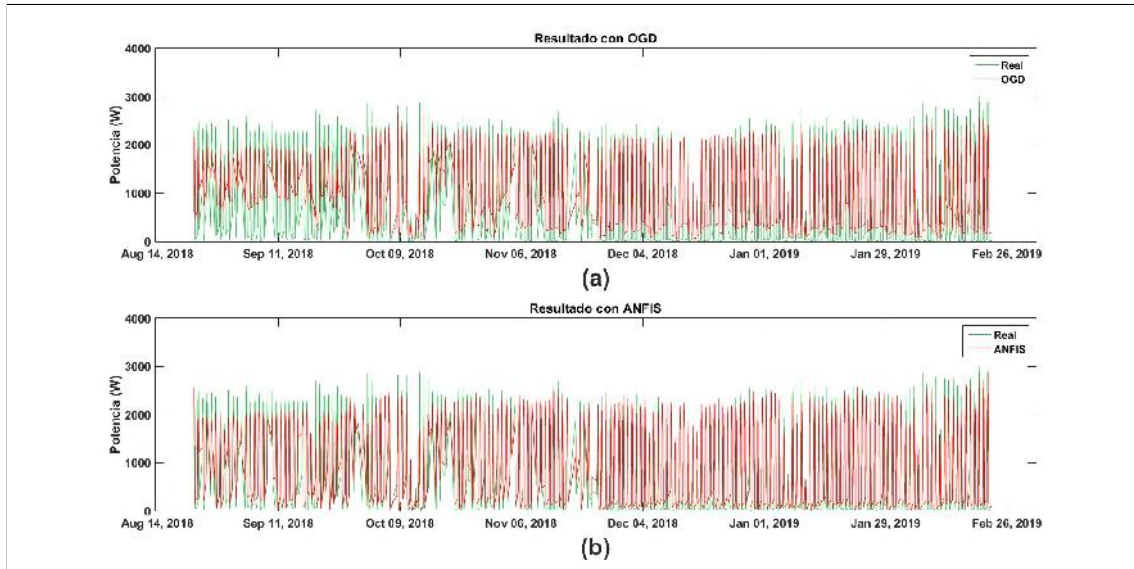


Figura 6.1: Resultados obtenidos usando los datos de entrenamiento. (a) Estimación por OGD contra datos reales; (b) Estimación por ANFIS contra datos reales.

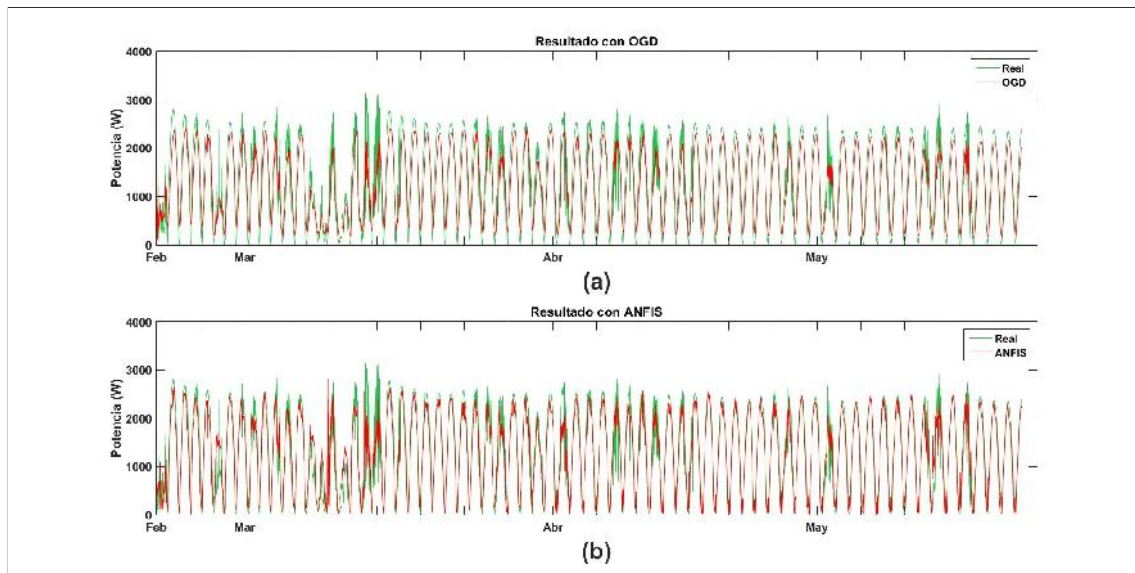


Figura 6.2: Resultados obtenidos usando los datos frescos. (a) Estimación por OGD contra datos reales; (b) Estimación por ANFIS contra datos reales.

## 6.2. Análisis de precisión

El análisis comparativo utilizando la correlación mencionada en la sección 5.1.1 se puede apreciar gráficamente a través de la Figura 6.3 en la cual se muestran las gráficas de dispersión de los modelos OGD y ANFIS tanto con datos de entrenamiento como con datos frescos. Claramente se logra apreciar un comportamiento lineal de los datos puntuales (verde) el cual se comprueba por la línea de tendencia (roja) indicando que la estimación de los modelos implementados es lineal y directamente proporcional a los valores reales; sin embargo, comparando la Figura 6.3(a) contra la 6.3(c) y la Figura 6.3(b) contra la 6.3(d) es posible identificar una mejoría por parte del método inteligente sobre el estadístico obteniendo una correlación de datos más cercana a su respectiva línea de tendencia, alcanzando una menor dispersión en ambos casos del modelo neuro-difuso.

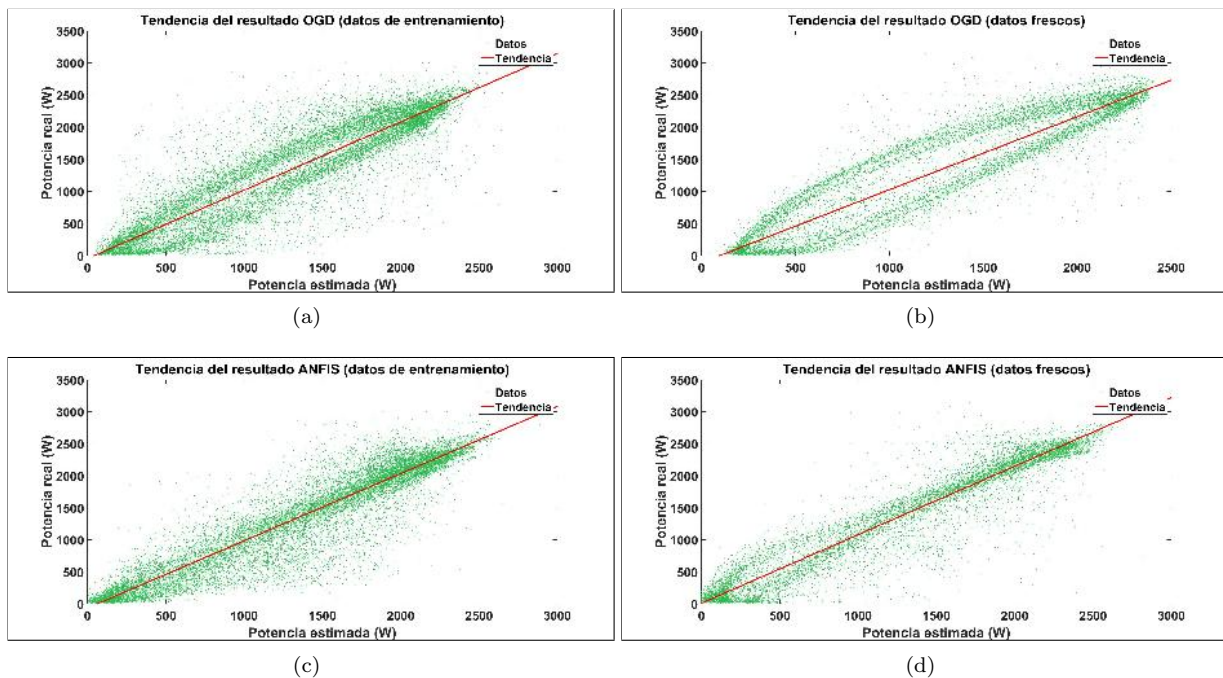


Figura 6.3: Gráficas de dispersión de las estimaciones obtenidas. (a) Estimación por OGD usando los datos de entrenamiento; (b) Estimación por OGD usando los datos frescos; (c) Estimación por ANFIS usando los datos de entrenamiento; (d) Estimación por ANFIS usando los datos frescos;

El primer error a utilizar se le conoce como Raíz Cuadrada del Error Cuadrático Medio o RMSE por sus siglas en inglés (Root Mean Square Error) y está definido por la Ecuación (6.7) donde  $P_m$  es la potencia medida,  $P_e$  es la potencia estimada,  $s$  es la muestra de datos a considerar y  $N$  es la cantidad total de muestras. El segundo es una modificación del RMSE el cual toma el resultado anterior y en relación con el máximo obtenido de los datos reales encuentra el porcentaje de error, a este error se le conoce como Error Cuadrático Medio Normalizado o nRMSE (Normalized Root Mean Square Error) descrito por la Ecuación (6.8). De igual manera el tercer error conocido como Error Porcentual Cuadrático Medio o RMSPE (Root Mean Square Percentage Error), descrito por la Ecuación (6.9), busca el porcentaje del error basado en el RMSE con la diferencia de que el máximo del valor medido se considera para encontrar la razón entre cada diferencia  $P_m - P_e$  y no para el resultado general como en el nRMSE [64–67].

Otro error conocido por su uso para valorar los sistemas inteligentes es el Error Absoluto Medio o MAE (Mean Absolute Error) descrito por la Ecuación (6.10). Este método es muy parecido al RMSE con la excepción del uso del valor absoluto en la diferencia  $P_m - P_e$  en lugar de la potencia y la raíz cuadrada general. A su vez este método también cuenta con su representación porcentual denominada Error Porcentual Absoluto Medio o MAPE (Mean Absolute Percentage Error) descrito por la Ecuación (6.11), y tal como en el RMSPE, éste aplica el máximo para encontrar la razón entre cada diferencia  $P_m - P_e$  [64–66].

$$RMSE = \sqrt{\frac{\sum_{s=1}^N (P_m - P_e)^2}{N}} \quad (6.7)$$

$$nRMSE_{\%} = \frac{\sqrt{\frac{\sum_{s=1}^N |P_m - P_e|^2}{N}}}{\text{máx}(P_m)} \cdot 100 \quad (6.8)$$

$$RMSPE_{\%} = \sqrt{\frac{\sum_{s=1}^N \left(\frac{P_m - P_e}{\text{máx}(P_m)}\right)^2}{N}} \cdot 100 \quad (6.9)$$

$$MAE = \frac{\sum_{s=1}^N |P_m - P_e|}{N} \quad (6.10)$$

$$MAPE_{\%} = \frac{\sum_{s=1}^N \left| \frac{P_m - P_e}{\text{máx}(P_m)} \right|}{N} \cdot 100 \quad (6.11)$$

Dado que los resultados de la Figura 5.15 muestran un comportamiento senoidal,  $(P_m - P_e)/P_m$  no presenta el correcto error entre ambas señales. Considerando la Figura 6.4(a), si el valor medido tiene un nivel alto, entonces la razón entre  $|P_m - P_e|$  y  $P_m$  será baja; sin embargo, si el valor real medido se encuentra en un nivel bajo, la misma razón será alta o cercana a 1, como se aprecia en la Figura 6.4(b). De acuerdo a lo anterior, la razón en las Ecuaciones (6.9) y (6.11) fue modificada respecto al rango total de la señal real medida (max-min) para obtener un resultado confiable. Las Ecuaciones (6.12) y (6.13) representan el RMSPE y MAPE modificados, respectivamente.




Figura 6.4: Diferencia de errores entre valores  $P_m$  altos y bajos. (a) Valor de error cuando el dato real medido es alto; (b) Valor de error cuando el dato real medido es bajo.

$$RMSPE_{\%} = \sqrt{\frac{\sum_{s=1}^N \left( \frac{P_m - P_e}{\max(P_m) - \min(P_m)} \right)^2}{N}} \cdot 100 \quad (6.12)$$


$$MAPE_{\%} = \frac{\sum_{s=1}^N \left| \frac{P_m - P_e}{\max(P_m) - \min(P_m)} \right|}{N} \cdot 100 \quad (6.13)$$

Los resultados de implementar cada uno de los errores descritos en las Ecuaciones (6.7), (6.8), (6.10), (6.12) y (6.13) a los modelos obtenidos por OGD y ANFIS se visualizan en las Figuras 6.5 y 6.6 de las cuales en cada uno de los casos realizados el modelo inteligente alcanzó una mejor estimación teniendo un error (línea roja) siempre por debajo del estadístico (línea verde).


La Tabla 6.2 detalla numéricamente los valores obtenidos en cada método de precisión implementado. Es posible observar que para las estimaciones usando los datos de entrenamiento, el ANFIS superó aproximadamente por 60W al estadístico tanto en el RMSE y el MAE; así mismo, el modelo neuro-difuso obtuvo resultados porcentuales bajos alrededor del 10 % para el RMSPE y 7 % para el MAPE, mientras que el OGD alcanzó porcentajes aproximados del 12 % y 9 %, respectivamente.

De igual manera, contemplando las estimaciones con datos frescos la conclusión es la misma resultando en un mejor desempeño por parte del ANFIS quien supera al OGD aproximadamente por 80W y obteniendo valores porcentuales 9.4307 % sobre 11.9392 % para RMSPE y 6.9851 % sobre 9.8152 % para el MAPE.


Finalmente, los coeficientes de determinación obtenidos por la correlación corroboran la excelencia del modelo inteligente quien alcanzó valores de 0.9720 y 0.9742 sobre el estadístico con solo 0.7581 y 0.9323, respectivamente. Esto comprueba la mejoría mostrada gráficamente en las Figuras 6.5 y 6.6.




(a) RMSE comparativo entre OGD y ANFIS.




(b) nRMSE comparativo entre OGD y ANFIS.



(c) RMSPE comparativo entre OGD y ANFIS.




(d) MAE comparativo entre OGD y ANFIS.




(e) MAPE comparativo entre OGD y ANFIS.


Figura 6.5: Comparación de los errores entre OGD y ANFIS usando los datos de entrenamiento. (a) RMSE; (b) nRMSE; (c) RMSPE; (d) MAE; (e) MAPE.




(a) RMSE comparativo entre OGD y ANFIS.




(b) nRMSE comparativo entre OGD y ANFIS.



(c) RMSPE comparativo entre OGD y ANFIS.



(d) MAE comparativo entre OGD y ANFIS.



(e) MAPE comparativo entre OGD y ANFIS.

Figura 6.6: Comparación de los errores entre OGD y ANFIS usando los datos frescos. (a) RMSE; (b) nRMSE; (c) RMSPE; (d) MAE; (e) MAPE.

Tabla 6.2: Resultados de valores de precisión.

Método	Datos de entrenamiento		Datos frescos	
	GDO	ANFIS	GDO	ANFIS
RMSE	363.7897 W	303.7429 W	373.8093 W	295.2687 W
nRMSE	0.0951 %	0.0794 %	0.1202 %	0.0950 %
RMSPE	12.1449 %	10.1402 %	11.9392 %	9.4307 %
MAE	270.7144 W	207.3163 W	307.3090 W	218.6996 W
MAPE	9.0376 %	6.9211 %	9.8152 %	6.9851 %
R <sup>2</sup>	0.7581	0.9720	0.9323	0.9742

### 6.3. Conclusiones del capítulo

En este capítulo se pudo observar y demostrar que el método inteligente ANFIS logra su propósito alcanzando una estimación satisfactoria de la potencia fotovoltaica, superando el desempeño de estimaciones realizadas a través del RLM y OGD como métodos estadísticos. Cabe mencionar que aunque la carga computacional para calcular la estimación por OGD es considerablemente menor a la necesitada en el modelo inteligente debido a la matemática descrita en la sección 5.1.2, el resultado obtenido es superado notablemente por el modelo neuro-difuso siendo este la mejor opción para lograr el objetivo; mientras que, el RLM no logró reproducir el comportamiento de la potencia por lo que se puede concluir que dicho método no puede ser aplicable para cualquier caso de estimación. Finalmente, se comprobó que el ANFIS es la técnica óptima para lograr estimar, en la modalidad de predictiva, la potencia fotovoltaica de acuerdo a las variables meteorológicas de su entorno.

# Capítulo 7

## Conclusiones y trabajos futuros

### 7.1. Conclusiones

Las energías renovables representan una alternativa potencial en la transición a una sociedad con bajos consumos de carbón o energías contaminantes, donde fuentes fotovoltaicas juegan un papel clave; sin embargo, los consumidores también son inversionistas y un proyecto sólo se llegará a implementar si las condiciones económicas son verificadas. Las tecnologías solares se caracterizan dependiendo la forma en que capturan, convierten o distribuyen la luz solar tal como sistemas fotovoltaicos y sus correspondientes requerimientos para el arreglo de su almacenamiento.

Una planeación cuidadosa es necesaria para administrar la futura demanda energética de sistemas fotovoltaicos debido a su creciente potencial en el país; por lo tanto, es vital entender la influencia de las variables meteorológicas en el consumo de energía en el cual una mejor comprensión puede contribuir a una mejor estrategia para lograr la eficiencia energética de la nación.

Las técnicas inteligentes han adquirido mundialmente una reputación de métodos simples para representar y replicar el comportamiento de procesos con desempeños no tan conocidos. Estas técnicas tienen el potencial de modelar, con precisión, procesos lineales y no lineales.

La importancia de lograr o alcanzar un modelo inteligente satisfactorio con el mínimo error entre lo estimado y el valor real es crucial en estudios de precisión o en tareas de administración en las cuales ciertas diferencias entre ambos pueden resultar en problemas económicos o pérdida de información.

### 7.2. Trabajos futuros

Este trabajo es fundamento y base para futuros estudios en el área de energía y sistemas fotovoltaicos permitiendo múltiples innovaciones. Todo sistema que se rige por eventos estocásticos presenta un comportamiento determinado tanto por acciones predecibles del proceso como por elementos aleatorios. La generación de potencia fotovoltaica necesita de la incidencia de radiación solar la cual es un proceso estocástico y debido a ello los equipos utilizados para su medición y captura deben tener la capacidad de superar los cambios aleatorios del proceso para su registro exitoso; sin embargo, no existe dispositivo alguno que proporcione una eficiencia del 100 %. Debido a lo anterior, la pérdida de información a registrarse es un problema común a considerar y tratar de evitar por lo que como trabajo a futuro la implementación de un observador al modelo inteligente obtenido permitirá la estimación de valores en tiempos donde la medición real haya sido imposible.

El poder estimar de manera satisfactoria la cantidad de potencia fotovoltaica que logra generar una planta solar dependiendo de las variables meteorológicas de la ubicación en la que se encuentra, conlleva a la posibilidad de dimensionar dichos sistemas de acuerdo con las condiciones del entorno obteniendo la generación de energía necesaria con la mejor eficiencia energética posible. Consecuentemente, la inclusión de más variables al modelo tales como contaminación del aire, salinidad, longitud y latitud, altura o incluso detalles no meteorológicos como tipo de panel solar, tipo de inversor, área disponible para la implementación del sistema, entre otros podrá resultar en un estudio más preciso y un mejor dimensionamiento de acuerdo a las necesidades del consumidor.

Un sistema inteligente neuro-difuso requiere de un compendio de datos para su posible entrenamiento, mientras el compendio sea mayor el ANFIS entenderá mejor el sistema a estimar y logrará un óptimo entrenamiento. Para



mejorar el trabajo aquí presentado una mayor cantidad de datos para el entrenamiento probablemente evitaría ciertos errores de estimación y se acercaría aun más a lo deseado. Un año es el mínimo período de tiempo en el cual se toman en cuenta las 4 estaciones climatológicas y por ende contempla todos los cambios meteorológicos los cuales se repetirán con cierto grado de exactitud al siguiente año. Por lo anterior, el compendio mínimo de un año para entrenar el modelo ANFIS podría lograr una mejoría en la estimación ya que comprendería el comportamiento del patrón anual de dichos datos.

El modelo ANFIS implementado en modo predictor logró una estimación satisfactoria durante la cantidad total de datos frescos; sin embargo, un aumento en la cantidad de dichos datos permitirá determinar exactamente la cantidad de tiempo que el modelo logra estimar en modo predictor debido a su autorecursividad. Lo anterior podría analizarse fuera o en línea.

# Bibliografía

- [1] J. Oviedo-Salazar, M. Badii, A. Guillen, and O. L. Serrato, “Historia y uso de energías renovables history and use of renewable energies,” *Daena Int. J. Good Conscience*, vol. 10, no. 1, pp. 1–18, 2015.
- [2] C. Philibert, *Solar energy perspectives*. OECD, 2011.
- [3] B. Dudley, “Bp energy outlook 2040,” *BP plc*, 2018.
- [4] I. Zuñiga-López and E. Crespo del Arco, *Meteorología y climatología*. UNED - Universidad Nacional de Educación a Distancia, 2000.
- [5] C. M. Rasero, “Energía solar fotovoltaica,” *Energía solar fotovoltaica, situación actual*, 2011.
- [6] Z. Wen-Tao, W. Shuai, and D. Xin-Hui, “Research of power prediction about photovoltaic power system: Based on bp neural network,” *JOURNAL OF ENVIRONMENTAL PROTECTION AND ECOLOGY*, vol. 18, no. 4, pp. 1614–1623, 2017.
- [7] A. M. Elshurafa, S. R. Albardi, S. Bigerna, and C. A. Bollino, “Estimating the learning curve of solar pv balance-of-system for over 20 countries: Implications and policy recommendations,” *Journal of Cleaner Production*, 2018.
- [8] A. Zahedi, “Solar photovoltaic (pv) energy; latest developments in the building integrated and hybrid pv systems,” *Renewable Energy*, vol. 31, no. 5, pp. 711–718, 2006.
- [9] H. A. Kazem, J. H. Yousif, and M. T. Chaichan, “Modeling of daily solar energy system prediction using support vector machine for oman,” *International Journal of Applied Engineering Research*, vol. 11, no. 20, pp. 10 166–10 172, 2016.
- [10] A. B. Awan, M. Zubair, A. G. Abokhalil *et al.*, “Solar energy resource analysis and evaluation of photovoltaic system performance in various regions of saudi arabia,” *Sustainability*, vol. 10, no. 4, p. 1129, 2018.
- [11] A.-J. Perea-Moreno, Q. Hernandez-Escobedo, J. Garrido, and J. D. Verdugo-Diaz, “Stand-alone photovoltaic system assessment in warmer urban areas in mexico,” *Energies*, vol. 11, no. 2, p. 284, 2018.
- [12] G. F. Nemet, E. O’Shaughnessy, R. Wiser, N. Darghouth, G. Barbose, K. Gillingham, and V. Rai, “Characteristics of low-priced solar pv systems in the us,” *Applied Energy*, vol. 187, pp. 501–513, 2017.
- [13] World Bank Group, Global Solar Atlas. (2017). [Online]. Available: <https://globalsolaratlas.info/downloads/mexico>
- [14] C. Mendoza, “Viabilidad técnica-económica de una central solar termoeléctrica de colectores cilíndricos parabólicos para su implementación de méxico,” *UNAM, Marzo*, 2012.
- [15] Instituto Nacional para el Federalismo y el Desarrollo Municipal. (2018). [Online]. Available: <http://siglo.inafed.gob.mx/enciclopedia/EMM26sonora/mediofisico.html>
- [16] Central Intelligence Agency. (2018) The world factbook. [Online]. Available: <https://www.cia.gov/library/publications/the-world-factbook/geos/sp.html>
- [17] Central Intelligence Agency. (2018) The world factbook. [Online]. Available: <https://www.cia.gov/library/publications/the-world-factbook/geos/gm.html>
- [18] Central Intelligence Agency. (2018) The world factbook. [Online]. Available: <https://www.cia.gov/library/publications/the-world-factbook/geos/it.html>
- [19] World Bank Group, Global Solar Atlas. (2017). [Online]. Available: <https://globalsolaratlas.info/downloads/world>

- [20] Acceso a Datos de Radiación Solar en España. (2018). [Online]. Available: <http://www.adrase.com>
- [21] Solar Energy Industries Association. (2018). [Online]. Available: <https://www.seia.org/initiative-topics/solar-technologies>
- [22] M. Järvelä and S. Valkealahti, “Ideal operation of a photovoltaic power plant equipped with an energy storage system on electricity market,” *Applied Sciences*, vol. 7, no. 7, p. 749, 2017.
- [23] C.-L. Hor, S. J. Watson, and S. Majithia, “Analyzing the impact of weather variables on monthly electricity demand,” *IEEE transactions on power systems*, vol. 20, no. 4, pp. 2078–2085, 2005.
- [24] S. C. Ooi, A. Mardiana, and Y. Yusup, “Analysing meteorological variables, energy consumption and occupant behaviour in an office building in hot-humid climate zone,” *International Journal of Science and Research*, vol. 4, no. 5, pp. 88–93, 2015.
- [25] S. K. Gardiner and D. P. Crabb, “Examination of different pointwise linear regression methods for determining visual field progression,” *Investigative ophthalmology & visual science*, vol. 43, no. 5, pp. 1400–1407, 2002.
- [26] S. Verma, A. Bartosova, M. Markus, R. Cooke, M.-J. Um, and D. Park, “Quantifying the role of large floods in riverine nutrient loadings using linear regression and analysis of covariance,” *Sustainability*, vol. 10, no. 8, p. 2876, 2018.
- [27] F. Grimaccia, M. Mussetta, and R. Zich, “Neuro-fuzzy predictive model for pv energy production based on weather forecast,” in *Fuzzy Systems (FUZZ), 2011 IEEE International Conference on*. IEEE, 2011, pp. 2454–2457.
- [28] Y. Kashyap, A. Bansal, and A. K. Sao, “Solar radiation forecasting with multiple parameters neural networks,” *Renewable and Sustainable Energy Reviews*, vol. 49, pp. 825–835, 2015.
- [29] Y. Song and M. Park, “A study on estimation equation for damage and recovery costs considering human losses focused on natural disasters in the republic of korea,” *Sustainability*, vol. 10, no. 9, p. 3103, 2018.
- [30] Ş. Sağlam, “Meteorological parameters effects on solar energy power generation,” *WSEAS Transactions on Circuits and Systems*, vol. 9, no. 10, pp. 637–649, 2010.
- [31] S. Nam and J. Hur, “Probabilistic forecasting model of solar power outputs based on the naïve bayes classifier and kriging models,” *Energies*, vol. 11, no. 11, p. 2982, 2018.
- [32] L. Della Ceca, M. Micheletti, M. Freire, B. Garcia, A. Mancilla, G. Salum, E. Crinó, and R. Piacentini, “Solar and climatic high performance factors for the placement of solar power plants in argentina andes sites—comparison with african and asian sites,” *Journal of Solar Energy Engineering*, vol. 141, no. 4, p. 041004, 2019.
- [33] M. Ding, L. Wang, and R. Bi, “An ann-based approach for forecasting the power output of photovoltaic system,” *Procedia Environmental Sciences*, vol. 11, pp. 1308–1315, 2011.
- [34] J. H. Yousif, H. A. Kazem, N. N. Alattar, and I. I. Elhassan, “A comparison study based on artificial neural network for assessing pv/t solar energy production,” *Case Studies in Thermal Engineering*, vol. 13, p. 100407, 2019.
- [35] J. Son, Y. Park, J. Lee, and H. Kim, “Sensorless pv power forecasting in grid-connected buildings through deep learning,” *Sensors*, vol. 18, no. 8, p. 2529, 2018.
- [36] K. R. Kuamr and M. S. Kalavathi, “Ann-anfis based forecast model for predicting pv and wind energy generation,” in *Proceedings of the World Congress on Engineering*, vol. 1, 2016.
- [37] A. Bassam, O. May Tzuc, M. Escalante Soberanis, L. Ricalde, and B. Cruz, “Temperature estimation for photovoltaic array using an adaptive neuro fuzzy inference system,” *Sustainability*, vol. 9, no. 8, p. 1399, 2017.
- [38] A. F. Mashaly and A. Alazba, “Anfis modeling and sensitivity analysis for estimating solar still productivity using measured operational and meteorological parameters,” *Water Science and Technology: Water Supply*, vol. 18, no. 4, pp. 1437–1448, 2018.
- [39] L. Viscidi, “Mexico’s renewable energy future,” 2018.
- [40] Gobierno Federal - Secretaría de Energía, “Prospectivas de energías renovables 2012-2026,” 2012.

- [41] T. Saga, “Advances in crystalline silicon solar cell technology for industrial mass production,” *npg asia materials*, vol. 2, no. 3, p. 96, 2010.
- [42] B. Zaidi, “Introductory chapter: Introduction to photovoltaic effect,” in *Solar Panels and Photovoltaic Materials*. IntechOpen, 2018.
- [43] Energía solar. (2017). [Online]. Available: <https://solar-energia.net/definiciones/baterias.html>
- [44] T. Díaz Corcobado and G. Carmona Rubio, *Instalaciones Solares Fotovoltaicas*. McGraw Hill Interamericana de España S.L., 2010, iSBN: 8448171691.
- [45] J. M. F. Nava, “Estudio e implementacion de un convertidor multicelda apilable controlado por dsp,” 2004.
- [46] J. R. Hernández Norzagaray, “Implementación de un sistema automatizado de adquisición de datos meteorológicos y solarimétricos,” 1995. [Online]. Available: <http://tesis.uson.mx/digital/tesis/docs/7542/Capitulo3.pdf>
- [47] D. J. Matich, “Redes neuronales: Conceptos básicos y aplicaciones,” *Universidad Tecnológica Nacional, México*, 2001.
- [48] S. H. Chen, A. J. Jakeman, and J. P. Norton, “Artificial intelligence techniques: an introduction to their use for modelling environmental systems,” *Mathematics and computers in simulation*, vol. 78, no. 2-3, pp. 379–400, 2008.
- [49] N. Pitalua, U. C. Peñaloza, J. Ruz-Hernandez, and R. L. Jimenez, “Introducción a los sistemas inteligentes,” *Departamento de Editorial Universitaria (UABC), Mexicali, Baja California, Mexico*, 2008, iSBN por la Unison: 978-607-7782-17-9; iSBN por la UABC: 978-607-7753-47-6.
- [50] J.-S. Jang, “Anfis: adaptive-network-based fuzzy inference system,” *IEEE transactions on systems, man, and cybernetics*, vol. 23, no. 3, pp. 665–685, 1993.
- [51] M. A. Boyacioglu and D. Avci, “An adaptive network-based fuzzy inference system (anfis) for the prediction of stock market return: the case of the istanbul stock exchange,” *Expert Systems with Applications*, vol. 37, no. 12, pp. 7908–7912, 2010.
- [52] M. Trujillo-Camacho, C. García-Gómez, J. Hinojosa-Palafox, and F. Castellón-Barraza, “Evaluación de compositos tio2/clinoptilolita en la fotodegradación del tinte mv-2b en un reactor-concentrador solar cpc,” *Revista mexicana de ingeniería química*, vol. 9, no. 2, pp. 139–149, 2010.
- [53] L. López-Sosa, L. Hernández-Ramírez, M. González-Avilés, H. Servín-Campuzano, and J. Zárate-Medina, “Desarrollo de un recubrimiento absorbente solar de bajo costo basado en hollín de biomasa forestal: Caracterización térmica y aplicación en un sistema de cocción solar,” *Revista Mexicana de Ingeniería Química*, vol. 17, no. 2, pp. 651–668, 2018.
- [54] M. González-Avilés, L. López-Sosa, H. Servín-Campuzano, and D. González-Pérez, “Adopción tecnológica sustentable de cocinas solares en comunidades indígenas y rurales de michoacán,” *Revista Mexicana de Ingeniería Química*, vol. 16, no. 1, 2017.
- [55] J. Benesty, J. Chen, Y. Huang, and I. Cohen, “Pearson correlation coefficient,” in *Noise reduction in speech processing*. Springer, 2009, pp. 1–4.
- [56] M. Spiegel and L. Stephens, “Estadística. 4ta edición, editorial mc,” *Graw Hill. México*, 2009.
- [57] R. Taylor, “Interpretation of the correlation coefficient: a basic review,” *Journal of diagnostic medical sonography*, vol. 6, no. 1, pp. 35–39, 1990.
- [58] A. Ng, “Cs229 lecture notes,” *CS229 Lecture notes*, vol. 1, no. 1, pp. 1–3, 2000.
- [59] A. Pérez-Vega, C. Travieso-González, and J. Hernández-Travieso, “An approach for multiparameter meteorological forecasts,” *Applied Sciences*, vol. 8, no. 11, p. 2292, 2018.
- [60] G. Notton, C. Voyant, A. Fouilloy, J. L. Duchaud, and M. L. Nivet, “Some applications of ann to solar radiation estimation and forecasting for energy applications,” *Applied Sciences*, vol. 9, no. 1, p. 209, 2019.
- [61] B. Elhami, A. Akram, M. Khanali, and S. H. Mousavi-Avval, “Application of anfis and linear regression models to analyze the energy and economics of lentil and chickpea production in iran,” *Energy Equipment and Systems*, vol. 4, no. 2, pp. 255–270, 2016.

- [62] C. T. Clack, “Modeling solar irradiance and solar pv power output to create a resource assessment using linear multiple multivariate regression,” *Journal of Applied Meteorology and Climatology*, vol. 56, no. 1, pp. 109–125, 2017.
- [63] D. C. Montgomery, *Design and analysis of experiments*. John wiley & sons, 2017.
- [64] A. Ahmad, M. Hassan, M. Abdullah, H. Rahman, F. Hussin, H. Abdullah, and R. Saidur, “A review on applications of ann and svm for building electrical energy consumption forecasting,” *Renewable and Sustainable Energy Reviews*, vol. 33, no. 1, pp. 102–109, 2014.
- [65] S. Ferlito, M. Atrigna, G. Graditi, S. De Vito, M. Salvato, A. Buonanno, and G. Di Francia, “Predictive models for building’s energy consumption: An artificial neural network (ann) approach,” in *2015 xviii aisem annual conference*. IEEE, 2015, pp. 1–4.
- [66] A. Sauhats, R. Petrichenko, Z. Broka, K. Baltputnis, and D. Sobolevskis, “Ann-based forecasting of hydropower reservoir inflow,” in *2016 57th International Scientific Conference on Power and Electrical Engineering of Riga Technical University (RTUCON)*. IEEE, 2016, pp. 1–6.
- [67] S. Leva, A. Dolara, F. Grimaccia, M. Mussetta, and E. Ogliari, “Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power,” *Mathematics and computers in simulation*, vol. 131, pp. 88–100, 2017.

# Apéndice A

## Descarga de datos del Inversor GALVO 3.1-1

### A.1. Creación de un equipo virtual

Primeramente se debe instalar el software Fronius Solar.Access. Una vez instalado se debe registrar o crear un equipo “virtual” representativo del inversor físico con el cual se enlazará y podrá descargar la información. Para ello se ejecuta el programa y se selecciona la pestaña *Administración* en la cual se muestran varias opciones de entre las cuales se elige *Crear un equipo* como se visualiza en la Figura A.1.

A continuación se necesita ingresar los datos de registro para el equipo virtual tal como se muestra en la Figura A.2. Para este trabajo el nombre del equipo es galvounison, el país es México, la zona horaria es (GMT - 7:00) debido a la ubicación en Hermosillo, Sonora. Dado que para lo requerido no se necesita el dato de remuneración (ahorro monetario por energía generada) se le da el valor de cero y es por esta misma razón que no importa la divisa seleccionada; en este caso se eligió dolares (USD). Lo más importante de esta sección es el registro del tipo de conexión ya que para este trabajo se utilizó una conexión Ethernet (LAN) por su facilidad y seguridad de obtención de datos en sitio. Al elegir dicha opción, una segunda aparece debajo indicando la dirección de red que por fábrica es 169.254.0.180. Una vez que todos los datos fueron registrados se procede a guardar.

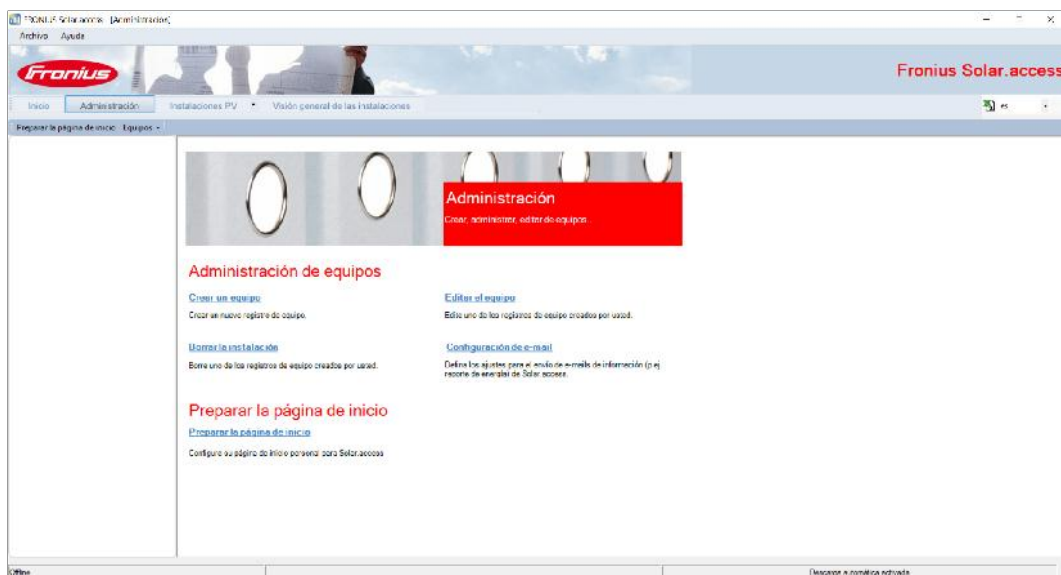


Figura A.1: Crear un equipo.

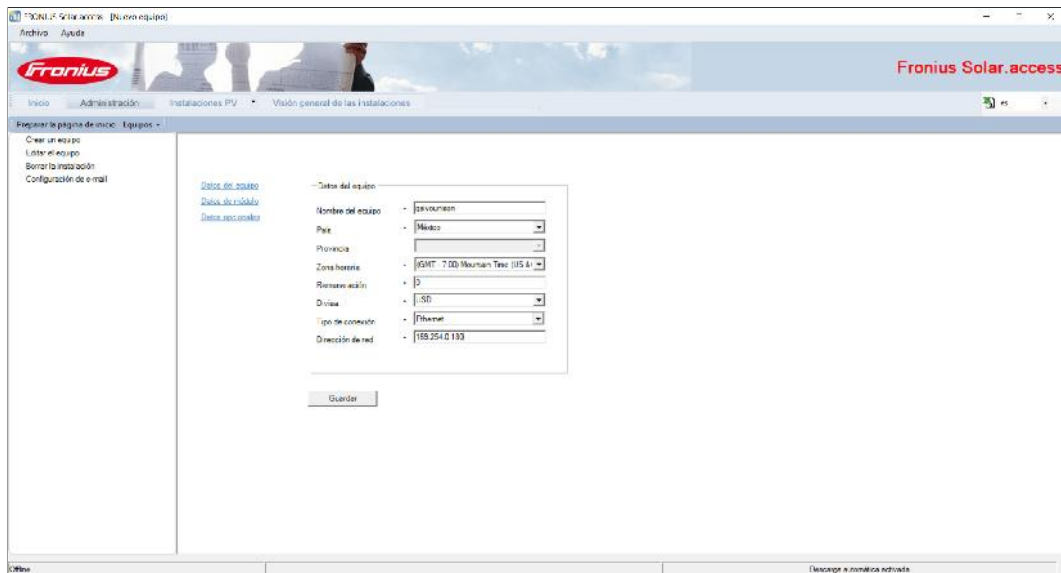


Figura A.2: Datos del equipo.

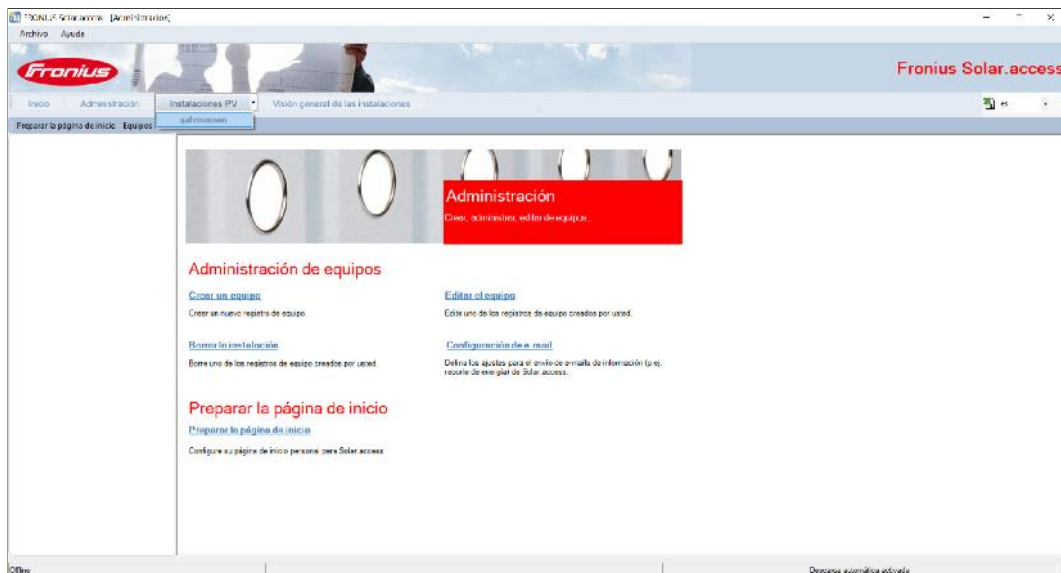


Figura A.3: Equipo creado.

En la Figura A.3 al seleccionar la pestaña *Instalaciones PV* se visualiza el equipo previamente creado.

## A.2. Descarga de datos en el sitio por LAN

Una vez teniendo seleccionado el equipo se procede a realizar la descarga de los datos para lo cual es necesario primero conectar el equipo virtual con el hardware y consecuentemente efectuar la descarga. En la Figura A.4 se muestra el equipo creado junto con sus correspondientes datos antes ingresados. Se debe seleccionar la opción *Conectar* localizada en la parte superior izquierda bajo la barra de herramientas del software. Automáticamente el programa ejecutará la conexión.

**Nota:** Se debe recordar que para que se logre llevar a cabo la conexión, de manera física, el dipswitch debe ser conmutado de su estado B al A como se mencionó en la Sección 2.1.4.

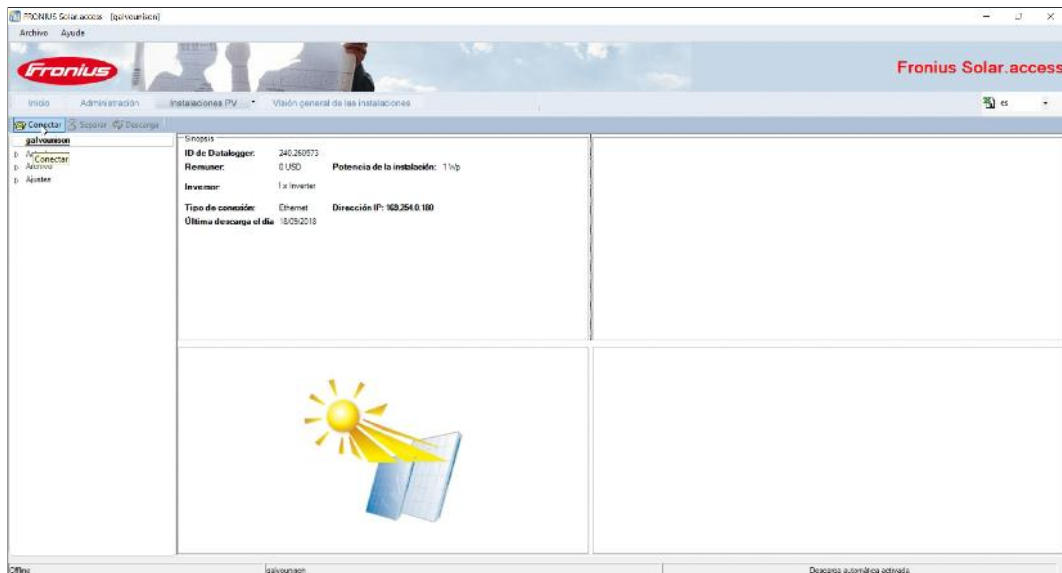


Figura A.4: Conectar con el inversor.

Como se puede apreciar de la Figura A.5 el equipo virtual ha sido conectado desplegando en la parte inferior izquierda de la pantalla la leyenda *Online* y entre parentesis la versión del software.

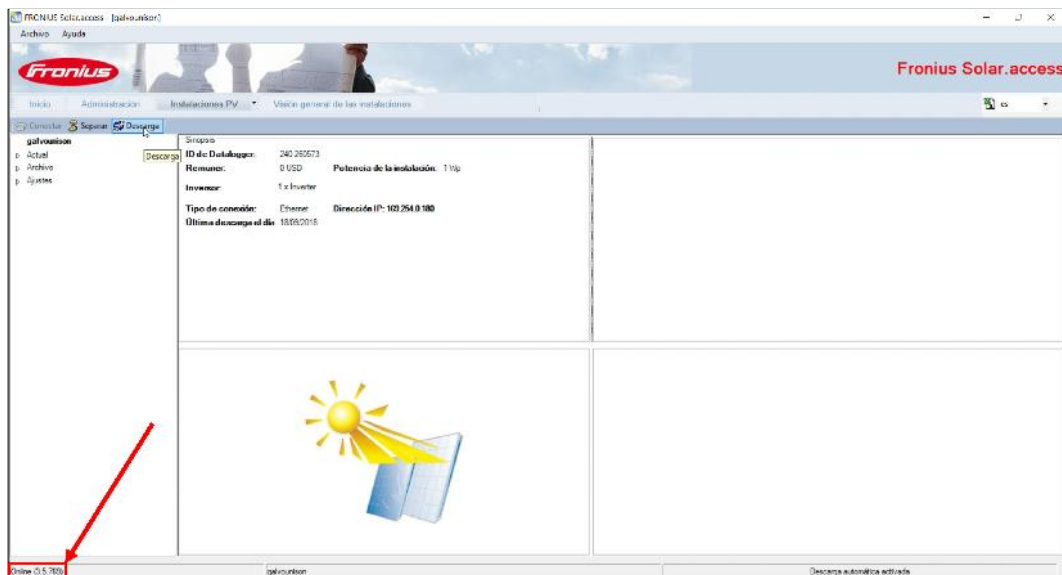


Figura A.5: Conectado.

Ya con el inversor físico y el equipo virtual conectados a través del cable Ethernet se procede a la descarga de los datos. Para ello es necesario elegir la opción *Descarga* ubicada en la parte superior izquierda bajo la barra de herramientas del software.

La ventana de descarga se ejecuta como se ve en la Figura A.6 en la cual aparecen dos secciones. La primera corresponde al periodo de tiempo de descarga en la cual hay tres opciones:

1. **Desde la última descarga** - Descarga la información adquirida a partir del último dato descargado (siempre y cuando hubiera una descarga anterior).
2. **Todo el contenido del Datalogger** - Descarga todos los datos que se tengan almacenados hasta la actualidad.
3. **Seleccionar una fecha** - Descarga un periodo de tiempo específico dado por el usuario.





Figura A.6: Selección del periodo de descarga.



Figura A.7: Inicio de descarga.

La segunda sección se refiere al comportamiento de datos de importación teniendo dos opciones a su vez:

1. **Adjuntar** - Los datos ya descargados con anterioridad no son alterados mientras que nuevos datos sólo son agregados.
2. **Sobreescribir** - Borra los datos que se tengan almacenados y guardar a su vez la nueva información.

Una vez se hallan elegido las opciones correctas, en este caso *Seleccionar una fecha* y *Adjuntar*, se selecciona *Continuar* y consecuentemente *Iniciar la descarga* como se ve en la Figura A.7.

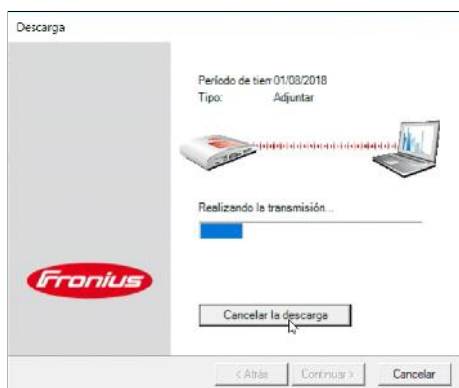


Figura A.8: Visualización de la descarga de datos.



Figura A.9: Descarga finalizada.

La Figura A.8 muestra la visualización de la descarga en pantalla, el tiempo requerido para la completa descarga es directamente proporcional al periodo de tiempo antes declarado.

Habiendo terminado exitosamente, se muestra en pantalla la leyenda “La descarga ha tenido éxito”, el periodo de tiempo elegido y la cantidad de datos descargados en función de bytes junto con el tiempo total (Figura A.9).

El proceso llevado a cabo de la Figura A.6 a la A.9 describe la descarga de datos para almacenarse en la máquina a la cual se conectó el inversor (PC o Laptop) y sea posible ver el comportamiento solamente a través del software Solar.Access; sin embargo, para su uso dichos datos deben de ser exportados a una hoja de Excel. Para ello en la pantalla del software, tal como se ve en la Figura A.10 donde se muestra el comportamiento de la energía generada por el inversor en el periodo de tiempo declarado, se elige la opción *Exportación de MS Excel* simbolizado por el ícono de una hoja de Excel ubicado en la parte superior derecha de la pantalla.



Figura A.10: Exportación de datos a Excel.

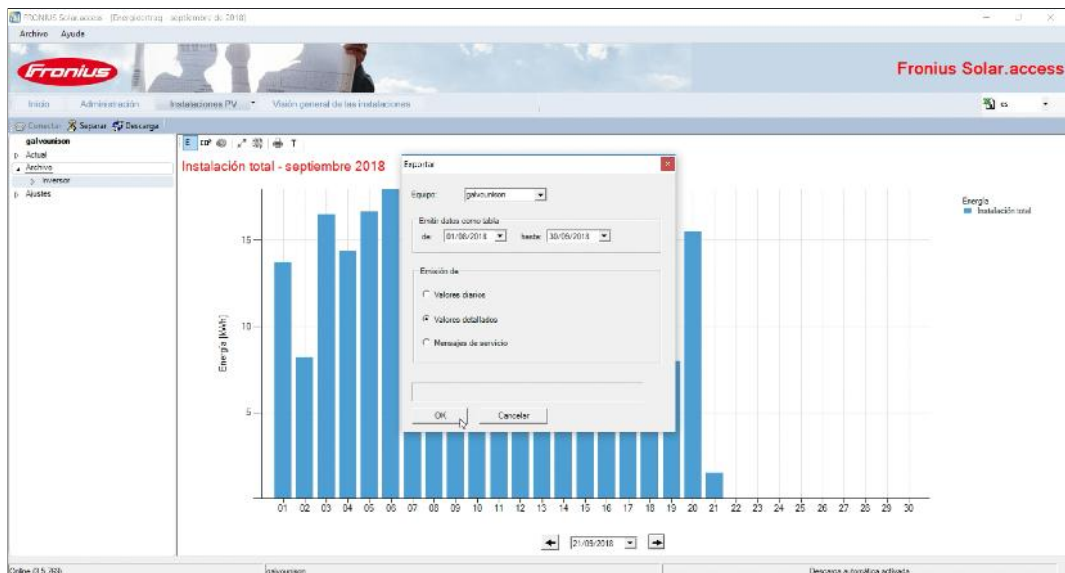


Figura A.11: Selección del periodo a exportar a Excel.

De igual manera que en la Figura A.6, una ventana se muestra indicando el periodo de tiempo del cual se requieren los datos para exportarse a Excel y a su vez una segunda sección en la cual se debe elegir la emisión de qué datos enviar.

1. **Valores diarios** - Exporta únicamente los valores de la potencia generada durante el periodo de tiempo determinado.
2. **Valores detallados** - Exporta tanto los valores de la potencia como la hora y fecha de su generación.
3. **Mensajes de servicio** - Exporta las notificaciones del inversor propias de su funcionamiento.

Una vez se hayan elegido las opciones requeridas, en este caso *Valores detallados* se da comienzo a la exportación la cual pedirá un destino para almacenar el documento de Excel y un nombre, consecuentemente la exportación dará comienzo como se aprecia en la Figura A.12.

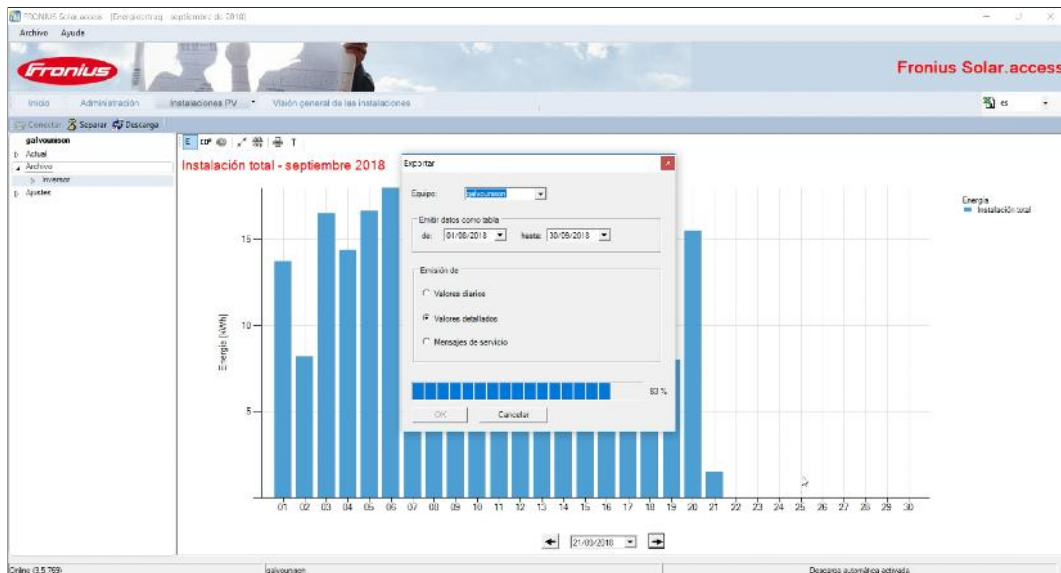


Figura A.12: Visualización de la exportación de datos a Excel.

## A.3. Visualización del inversor en línea

### A.3.1. Por conexión inalámbrica

Como se mencionó en la sección 2.1.4 se debe tener descargada la aplicación Solar.web la cual, gracias a su asistente, detalla los pasos a seguir. La Figura A.13 muestra la selección del producto para monitorizar el cual para este caso es *Inversores de conexión a red*. Una vez seleccionado el segundo paso es activar el punto WiFi tal cual se visualiza en la Figura A.14, al hacerlo aparecerá en pantalla el ID del datalogger (almacenamiento de registros y datos) así como la contraseña del mismo, datos que serán necesarios mas adelante.



Figura A.13: Selección del producto Solar.web



Figura A.14: Punto WiFi Solar.web

Se conecta a dicho punto WiFi estableciendo la conexión inalámbrica e ingresando los datos del módem a utilizar. Automáticamente el inversor quedará registrado y se puede ver desde la página de Fronius generando una cuenta. Para registrar el inversor utilizado se toma el ID del datalogger y se ingresa en la plataforma.

### A.3.2. Por conexión LAN

Para establecer una conexión alámbrica y poder visualizar el inversor en línea se requiere de la conexión LAN utilizando un cable Ethernet el cual cuente con internet. El primer paso es identificar la *dirección IP*, *máscara de subred*, *puerta de enlace predeterminada* y el *servidor DNS*.

Con el uso de una computadora, el inversor se conecta a través de un cable Ethernet, el switch del inversor se conmuta a la posición A y se ingresa a la IP 169.254.0.180. En pantalla se visualiza el inversor registrado de acuerdo a la sección A.1. En la pestaña *RED* se ingresan los datos requeridos de la conexión LAN antes mencionados y se selecciona la opción LAN como se visualiza en la Figura A.15.

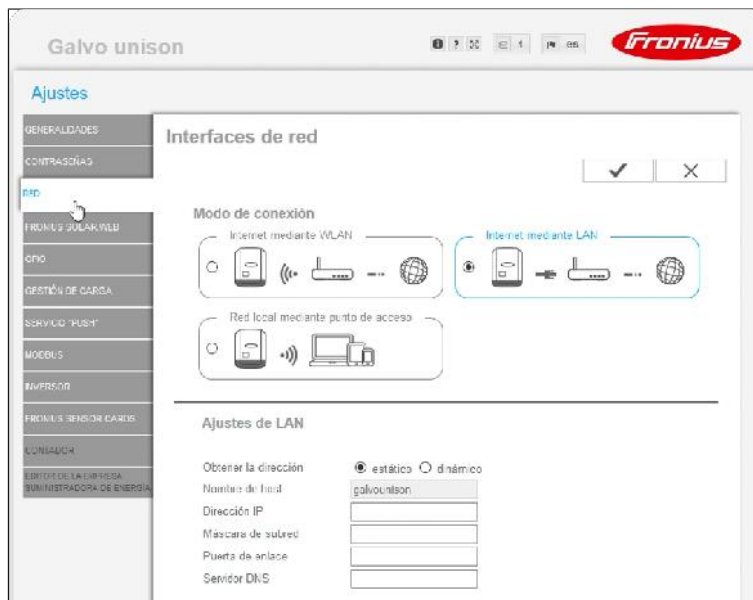


Figura A.15: Ingreso de datos para conexión LAN

Una vez realizados los pasos descritos, a través de la página de Fronius se puede monitorear el inversor, siempre y cuando se tenga registrada una cuenta tal y como se menciona en la sección A.3.1. La Figura A.16 visualiza el monitoreo del inversor y su desempeño a través del portal de Fronius.

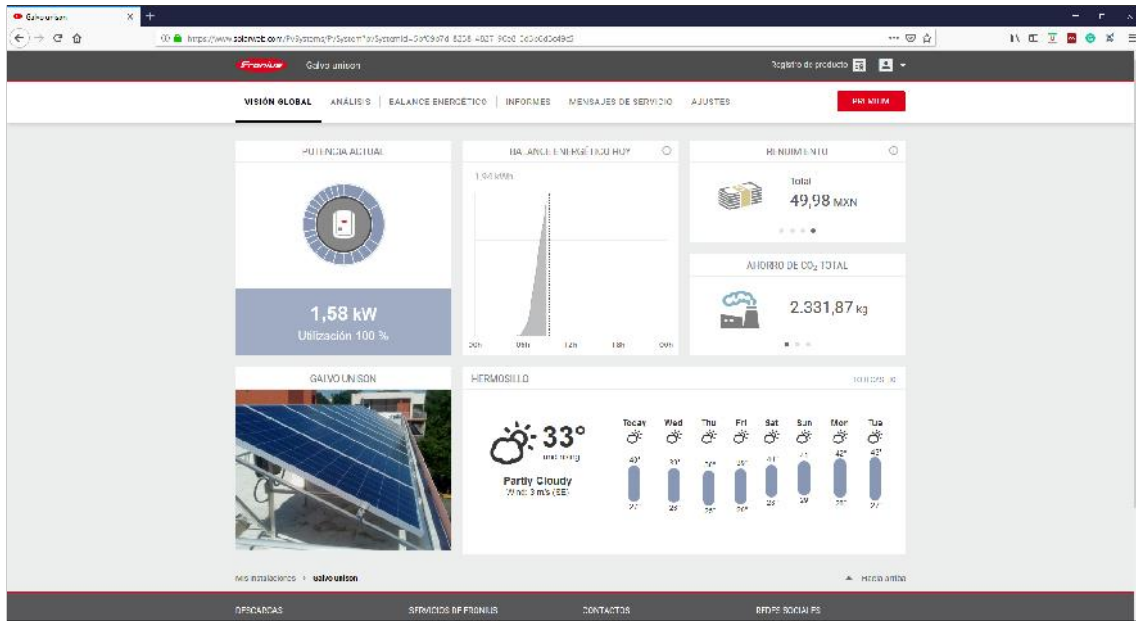


Figura A.16: Portal de Fronius Solar.Web

## Apéndice B

# Descarga de datos de la estación meteorológica VANTAGE PRO 2

### B.1. Descarga de datos y variables

La estación VANTAGE PRO2 permite la descarga de las variables monitoreadas a través de dos métodos.

1. A través del software *Weatherlink* gracias a una conexión TCP/IP. Para ello es necesario entrar al software *Weatherlink* y crear virtualmente una nueva estación ingresando sus características físicas (tipo de conexión, ubicación, etc.) así como su configuración en cuanto a manejo de la información. Una vez hecho esto se conecta la estación recién creada y se procede a la descarga de datos.
2. Accediendo al portal *www.weatherlink.com* se crea una cuenta de usuario y se registra la estación. Para ello es necesario un dispositivo llamado WeatherlinkIP Data Logger (Figura B.2) el cual se conecta físicamente con la consola de operación (Figura B.1) y una PC por medio de una conexión LAN, este dispositivo es el que permite la carga de datos al portal con el uso de la red a la cual está conectada la PC.




Figura B.1: Consola de operación DAVIS.



Figura B.2: Data Logger.

El proceso para configurar la estación meteorológica con el software *Weatherlink* y así poder descargar los datos se detalla a continuación:

El primero paso es descargar e instalar el software, en este caso se usa la versión 6.0.3. Una vez ejecutado el programa (Figura B.3) es necesario crear una estación virtual para vincularse con la VANTAGE PRO2. Para esto en la barra de herramientas en archivo se elige la opción *New Station* (Figura B.4) donde se le da el nombre con el cual se identificará la estación (DAVIS para el ejemplo). Acto siguiente comienza un ayudante para poder acceder toda la información requerida desde la configuración, comunicación, unidades de medición hasta la latitud y longitud de la estación física (Figuras B.5, B.6, B.7 y B.8 respectivamente). Cabe señalar que al establecer la comunicación se elige TCP/IP lo cual habilita la elección del tipo de conexión y se establece descarga por Web (Web Download) ingresando el usuario y contraseña que se encuentran ambos en el dispositivo WeatherlinkIP

conectado entre la consola y la PC. Habiendo generado correctamente la estación virtual ésta queda habilitada para la descarga de datos. La estación VANTAGE PRO2 ubicada en la UNISON ya se encontraba registrada y habilitada con el nombre **hmo**. Se selecciona el segundo botón de la barra de comandos *Download the weather station* (Figura B.9) para descargar los datos desde la última descarga hasta la fecha y consecuentemente se selecciona el sexto botón *Browse the station data* (Figura B.10) para visualizar en pantalla todo el histórico de datos (Figura B.11). Se puede apreciar que cada columna es una variable registrada mencionada en el Capítulo B.1. El paso final es la exportación de dicho histórico en formato txt. para poder manipularlos. En la barra de herramientas se elige *Browse* y seguidamente *Export Records...* (Figura B.12) lo cual abre una ventana que permite la selección del intervalo de tiempo que se desea exportar y finalmente guardar (Figura B.13).



Figura B.3: Software Weatherlink

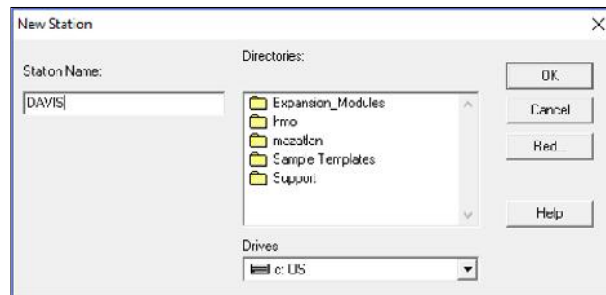


Figura B.4: Nueva estación

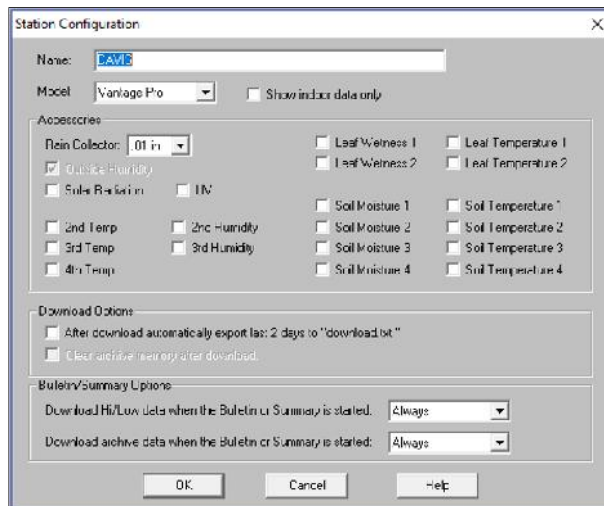


Figura B.5: Configuración de la estación

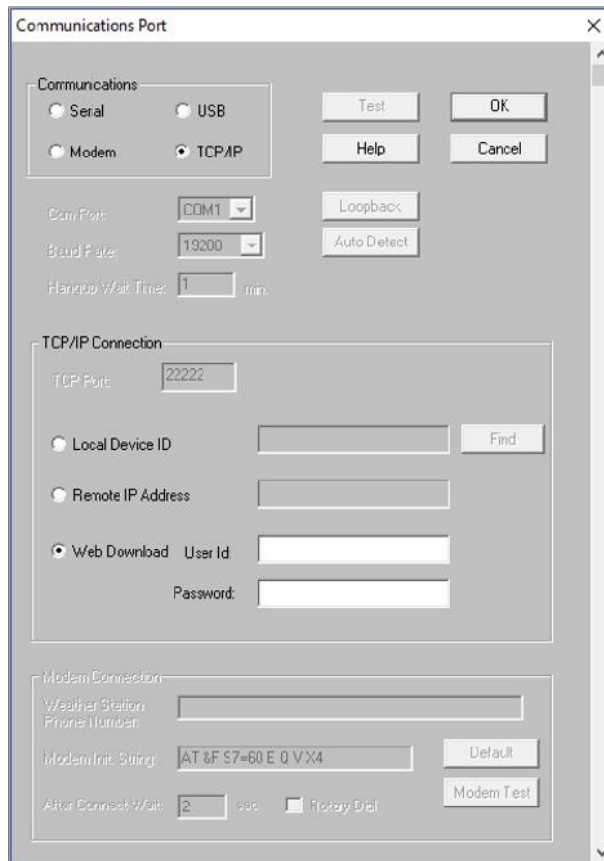


Figura B.6: Puertos de comunicación



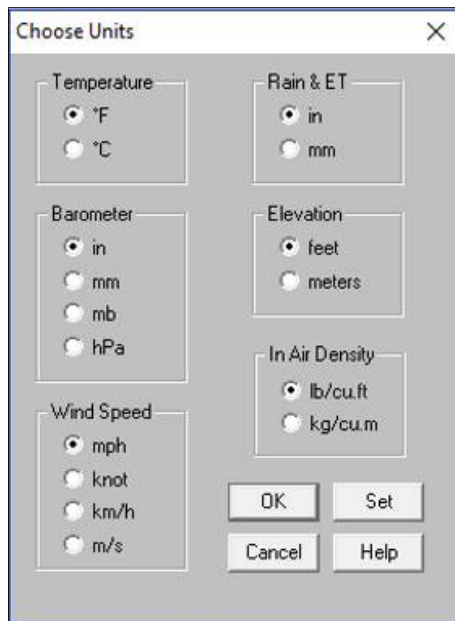


Figura B.7: Unidades de medición

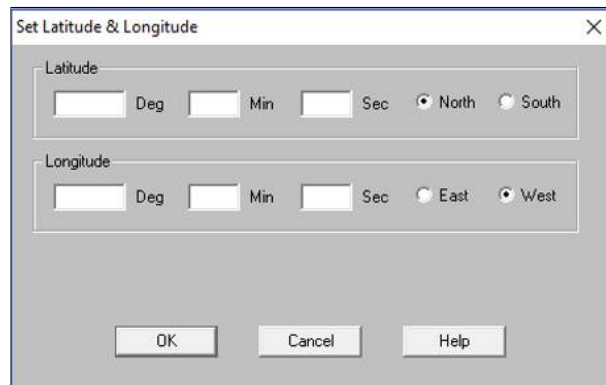


Figura B.8: Ubicación por latitud y longitud



Figura B.9: Opción de descarga



Figura B.10: Opción para visualizar el histórico

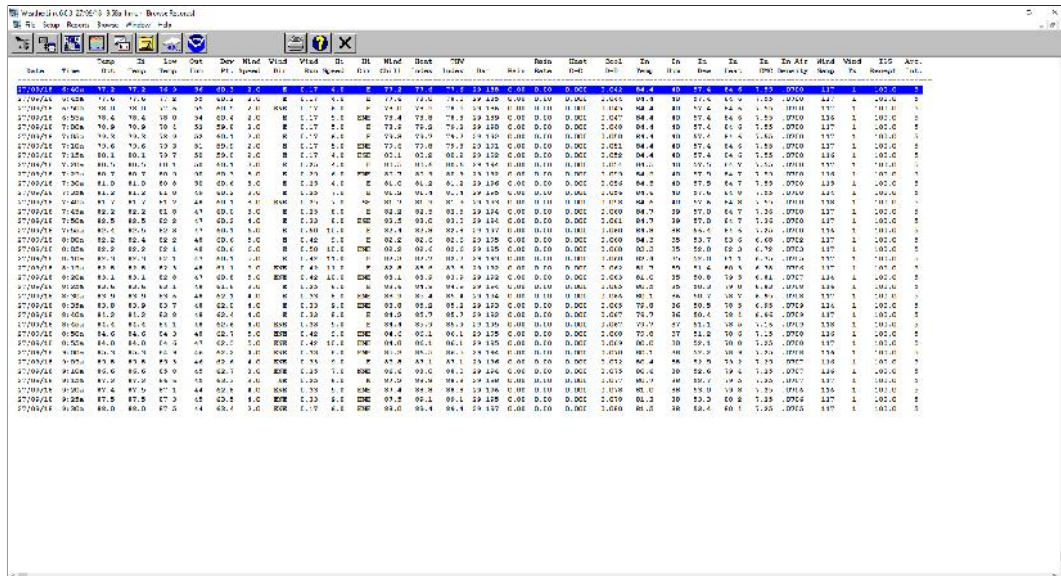


Figura B.11: Histórico de datos

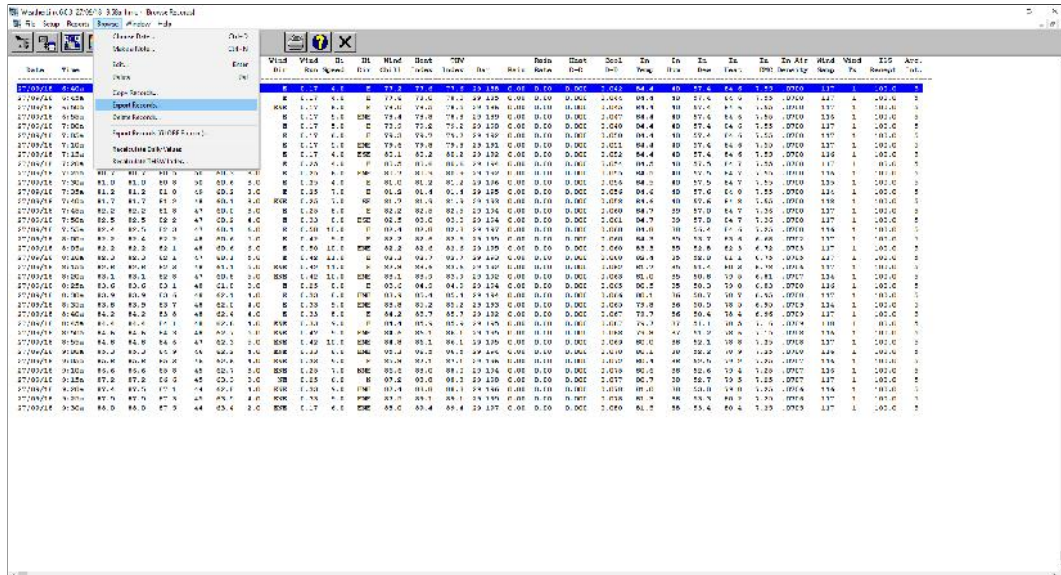


Figura B.12: Ruta para exportar el histórico

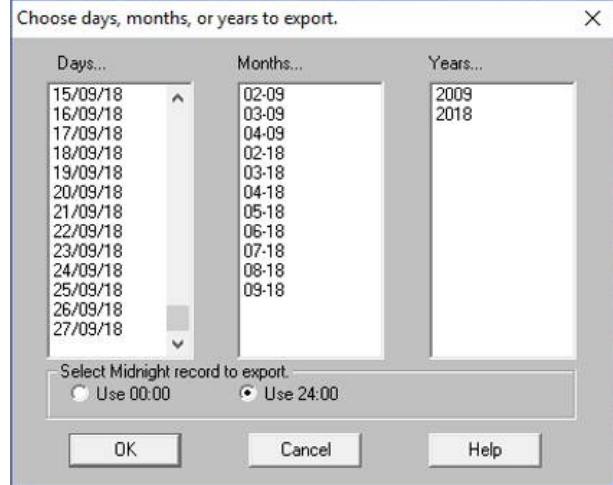


Figura B.13: Selección de la fecha a exportar









# Apéndice C

## Publicaciones

## C.1. Applied Sciences

Article

# Meteorological Variables' Influence on Electric Power Generation for Photovoltaic Systems Located at Different Geographical Zones in Mexico

Jose A. Ruz-Hernandez <sup>1</sup>, Yasuhiro Matsumoto <sup>2</sup>, Fernando Arellano-Valmaña <sup>1</sup>,  
Nun Pitalúa-Díaz <sup>3,\*</sup>, Rafael Enrique Cabanillas-López <sup>3</sup>, José Humberto Abril-García <sup>3</sup>,  
Enrique J. Herrera-López <sup>4</sup> and Enrique Fernando Velázquez-Contreras <sup>3</sup>

<sup>1</sup> Facultad de Ingeniería, Universidad Autónoma del Carmen, Calle 56 No. 4 Esq. Avenida Concordia Col. Benito Juárez, Cd. Del Carmen C.P. 24180, Campeche, Mexico; jruz@mail.unacar.com (J.A.R.-H.); ff.arellano@hotmail.com (F.A.-V.)

<sup>2</sup> Departamento de Ingeniería Eléctrica, Centro de Investigación y de Estudios Avanzados del IPN, Av. Instituto Politécnico Nacional 2508, San Pedro Zacatenco, Ciudad de México C.P. 07360, CDMX, Mexico; ymatsumo@cinvestav.mx

<sup>3</sup> Departamento de Ingeniería Industrial, Departamento de Ingeniería Química y Metalurgia, Departamento de Investigación en Polímeros y Materiales, Universidad de Sonora, Blvd. Luis Encinas y Rosales S/N, Col. Centro, Hermosillo C.P. 83000, Sonora, Mexico; rcabani@iq.uson.mx (R.E.C.-L.); jose.abril@unison.mx (J.H.A.-G.); evlzqz@guaymas.uson.mx (E.F.V.-C.)

<sup>4</sup> Biotecnología Industrial, Sublínea Bioelectrónica, Centro de Investigación y Asistencia en Tecnología y Diseño del Estado de Jalisco A.C., Camino Arenero 1227, Col. El Bajío del Arenal, Zapopan C.P. 45019, Jalisco, Mexico; eherrera@ciatej.mx

\* Correspondence: nun.pitalua@unison.mx; Tel.: +52-1662-114-0682

Received: 1 March 2019; Accepted: 10 April 2019; Published: 20 April 2019



**Abstract:** In this study, the relation among different meteorological variables and the electrical power from photovoltaic systems located at different selected places in Mexico were presented. The data was collected from on-site real-time measurements from Mexico City and the State of Sonora. The statistical estimation by the gradient descent method demonstrated that solar radiation, outdoor temperature, wind speed, and daylight hour influenced the electric power generation when it was compared with the real power of each photovoltaic system. According to our results, 97.63% of the estimation results matched the real data for Sonora and 99.66% the results matched for Mexico City, achieving overall errors less than 7% and 2%, respectively. The results showed an acceptable performance since a satisfactory estimation error was achieved for the estimation of photovoltaic power with a high determination coefficient  $R^2$ .

**Keywords:** photovoltaic systems; meteorological variables; electric power; gradient descent; sustainable development

## 1. Introduction

Renewables energies represent a potential alternative in the transition towards a low-carbon society, where photovoltaic sources play a key role; however, consumers are also investors and a project is implemented only if economic conditions are verified [1].

Solar technologies are characterized depending on the way they capture, convert, and distribute sunlight such as photovoltaic (PV) systems and their corresponding requirements for an energy storage arrangement [2,3]. Consequently, these technologies feed power to the electric grid by using solar panels as generators [4–6]. In addition, concentrating solar power plants (CSP) use mirrors to focus the

## C.2. Energies



*Article*

# An ANFIS-Based Modeling Comparison Study for Photovoltaic Power at Different Geographical Places in Mexico

Nun Pitalúa-Díaz <sup>1,\*</sup>, Fernando Arellano-Valmaña <sup>2</sup>, Jose A. Ruz-Hernandez <sup>2</sup>,  
Yasuhiro Matsumoto <sup>3</sup>, Hussain Alazki <sup>2</sup>, Enrique J. Herrera-López <sup>4</sup>,  
Jesús Fernando Hinojosa-Palafox <sup>1</sup>, A. García-Juárez <sup>1</sup>, Ricardo Arturo Pérez-Enciso <sup>1</sup>  
and Enrique Fernando Velázquez-Contreras <sup>1</sup>

<sup>1</sup> Departamento de Ingeniería Industrial, Departamento de Ingeniería Química y Metalurgia, Departamento de Investigación en Física, Departamento de Investigación en Polímeros y Materiales, Universidad de Sonora, Blvd. Luis Encinas y Rosales S/N, Col. Centro. Hermosillo 83000, Sonora C.P., Mexico

<sup>2</sup> Facultad de Ingeniería, Universidad Autónoma del Carmen, Calle 56 No. 4 Esq. Avenida Concordia Col. Benito Juárez C.P. 24180 Cd. Del Carmen, Campeche, Mexico

<sup>3</sup> Departamento de Ingeniería Eléctrica, Centro de Investigación y de Estudios Avanzados del IPN, Av. Instituto Politécnico Nacional 2508, La Laguna Ticoman, C.P. 07360 Ciudad de México, CDMX, Mexico

<sup>4</sup> Biotecnología Industrial, Sublínea Bioelectrónica, Centro de Investigación y Asistencia en Tecnología y Diseño del Estado de Jalisco A.C., Camino Arenero 1227, Col. El Bajío del Arenal, C.P. 45019 Zapopan Jalisco, Mexico

\* Correspondence: nun.pitalua@unison.mx; Tel.: +52-1-662-259-2159

Received: 5 June 2019; Accepted: 9 July 2019; Published: 11 July 2019



**Abstract:** In this manuscript, distinct approaches were used in order to obtain the best electrical power estimation from photovoltaic systems located at different selected places in Mexico. Multiple Linear Regression (MLR) and Gradient Descent Optimization (GDO) were applied as statistical methods and they were compared against an Adaptive Neuro-Fuzzy Inference System (ANFIS) as an intelligent technique. The data gathered involved solar radiation, outside temperature, wind speed, daylight hour and photovoltaic power; collected from on-site real-time measurements at Mexico City and Hermosillo City, Sonora State. According to our results, all three methods achieved satisfactory performances, since low values were obtained for the convergence error. The GDO improved the MLR results, minimizing the overall error percentage value from 7.2% to 6.9% for Sonora and from 2.0% to 1.9% for Mexico City; nonetheless, ANFIS overcomes both statistical methods, achieving a 5.8% error percentage value for Sonora and 1.6% for Mexico City. The results demonstrated an improvement by applying intelligent systems against statistical techniques achieving a lesser mean average error.

**Keywords:** ANFIS; statistical method; gradient descent; photovoltaic system; sustainable development

---

### 1. Introduction

Considerable research has been developed internationally in the field of photovoltaic systems and power generation [1–3]. Mexico is a country that receives abundant solar energy, with the northwest region being the one with the highest annual incidence of solar radiation, achieving radiation indexes between 5.6 and 6.2 kWh/m<sup>2</sup> per day; nevertheless, its advances on the photovoltaic field are scarce nowadays, although there are many possibilities of research in this topic [4].

*Energies* **2019**, *12*, 2662; doi:10.3390/en12142662

www.mdpi.com/journal/energies

### C.3. Congreso Interdisciplinario de Energías Renovables, Mantenimiento Industrial, Mecatrónica e Informática

**CIER**  
Colegio de Ingenieros de Energías Renovables

**TO**  
**CIERMMI**  
**2019**

**CONGRESO INTERDISCIPLINARIO DE ENERGÍAS RENOVABLES,  
MANTENIMIENTO INDUSTRIAL, MECATRÓNICA E INFORMÁTICA.**

**OTORGA LA PRESENTE  
CONSTANCIA  
A**

**ARELLANO VALMAÑA, FERNANDO**

**POR LA PARTICIPACIÓN DEL ARTÍCULO**

**Modelo predictivo inteligente para la generación de energía eléctrica en un sistema fotovoltaico**

Durante el 4to. Congreso Interdisciplinario de Energías Renovables, Mantenimiento Industrial, Mecatrónica e Informática,  
llevado a cabo los días 24 y 25 de octubre del 2019,  
en la ciudad de Santiago de Querétaro, Qro.

  
Dr. Ángel Martín Jiménez de Jesús  
COORDINADOR DEL CIERMMI 2019

  
Ing. Luis Eduardo Cruz Carpio  
DIRECCIÓN DE VINCULACIÓN





# UNACAR

Universidad Autónoma del Carmen  
“Por la Grandeza de México”

## ACUERDO PARA USO DE OBRA

A quien corresponda

**PRESENTE**

Por medio del presente escrito, **Fernando Arellano Valmaña** (en lo sucesivo EL AUTOR) hace constar que es titular intelectual de la obra denominada, “**Modelo predictivo inteligente para la producción de energía eléctrica en un sistema fotovoltaico**” (en lo sucesivo la OBRA), en virtud de lo cual autoriza a la Universidad Autónoma del Carmen (en lo sucesivo la UNACAR) para que efectué resguardo físico y/o electrónico mediante copia digital o impresa para asegurar su disponibilidad, divulgación, comunicación pública, distribución, transmisión, reproducción, así como digitalización de la misma con fines académicos y sin fines de lucro como parte de Repositorio Institucional de la UNACAR (*Runacar*).

De igual manera, es deseo del AUTOR establecer que esta autorización es voluntaria y gratuita, y que de acuerdo a lo señalado en la Ley Federal del Derecho de Autor y la Ley de Propiedad Industrial, la UNACAR cuenta con mi autorización para la utilización de la información antes señalada, estableciendo que se utilizará única y exclusivamente para los fines antes señalados. EL AUTOR autoriza a la UNACAR a utilizar las obras en los términos y condiciones aquí expresados, sin que ello implique que se le conceda licencia o autorización alguna o algún tipo de derecho distinto al mencionado respecto a la “propiedad intelectual” de la misma OBRA; incluyendo todo tipo de derechos patrimoniales sobre obras y creaciones protegidas por derechos de autor y demás formas de propiedad intelectual reconocida o que lleguen a reconocer las leyes correspondientes. Al reutilizar, reproducir, transmitir y/o distribuir la OBRA se deberá reconocer y dar crédito de autoría de la obra intelectual en los términos especificados por el propio AUTOR, y el no hacerlo implica el término de uso de esta licencia para los fines estipulados. Nada de esta licencia menoscaba o restringe los derechos patrimoniales y morales del AUTOR.

De la misma manera, se hace manifiesto que el contenido académico, literario, la edición y en general de cualquier parte de la OBRA son responsabilidad del AUTOR, por lo que se deslinda a la UNACAR por cualquier violación a los derechos de autor y/o propiedad intelectual, así como cualquier responsabilidad relacionada con la misma frente a terceros. Finalmente, el AUTOR manifiesta que estará depositando la versión final de su Tesis de maestría, OBRA y cuenta con los derechos morales y patrimoniales correspondientes para otorgar la presente autorización de uso.

En la ciudad de Carmen, del estado de Campeche a los 12 días el mes de noviembre de 2019.

Atentamente.

  
FERNANDO ARELLANO VALMAÑA

---

**Nombre y Firma Autógrafa de EL AUTOR**

Escriba la Facultad, Escuela, Centro a la que está suscrita la obra: Facultad de Ingeniería, Universidad Autónoma del Carmen, Campus III.