



UNIVERSIDAD AUTÓNOMA DE YUCATÁN

FACULTAD DE INGENIERÍA

UNIDAD DE POSGRADO E INVESTIGACIÓN

**PREDICCIÓN DE GENERACIÓN DE POTENCIA
DE ARREGLOS FOTOVOLTAICOS MEDIANTE
REDES NEURONALES DE ALTO ORDEN**

TESIS

PRESENTADA POR:

I.M. ROGER ALBERTO HEREDIA MORENO

EN OPCION AL GRADO DE:

MAESTRO EN INGENIERÍA

OPCION ENERGIAS RENOVABLES

MÉRIDA, YUCATÁN, MÉXICO

2017

Aunque este trabajo hubiere servido para el Examen de Grado y hubiera sido aprobado por el sínodo, sólo el autor es responsable de las doctrinas emitidas en él.

RESUMEN

Actualmente el empleo de energías alternativas se ha convertido en una prioridad prácticamente para todos los países, debido al inminente agotamiento de los combustibles fósiles y el incremento de la demanda energética. Los sistemas fotovoltaicos son una tecnología que aplica el efecto foto eléctrico en materiales semiconductores para convertir la energía radiante directamente en energía eléctrica. El estudio sobre la producción de energía a partir de fuentes fotovoltaicas es necesario ya que se tienen y se prevén grandes sistemas de producción de electricidad mediante el uso de la energía solar, además estos sistemas tendrán un gran impacto en los sistemas de energía existentes. En este trabajo de investigación se propone la obtención de un modelo matemático para la generación de potencia de un arreglo de paneles fotovoltaicos usando redes neuronales de alto orden. Primero se procesarán datos de las condiciones ambientales y generación de potencia. A partir de estos datos se planteará un modelo del comportamiento del arreglo fotovoltaico. Finalmente, mediante un criterio de error, se validará el modelo previo. Este modelo servirá para conocer la potencia que entregará el sistema dependiendo de las condiciones climáticas y fundamentará modelos de optimización de la generación de energía. El resultado de este trabajo es importante ya que los datos estimados pueden ser utilizados para mejorar el desempeño del arreglo, modificando las condiciones de temperatura.

ABSTRACT

Currently the use of alternative energy has been made a priority for almost all countries, due to the depletion of fossil fuels and the increase in energy demand. Photovoltaic systems are a technology that applies the photovoltaic effect in semiconductor materials to convert radiant energy directly into electrical energy. The study on the production of energy from photovoltaic sources is necessary since they have and are foreseen large systems of electricity production through the use of solar energy, in addition these systems will have a great impact in the existing energy systems. In this research to obtain a mathematical model for power generation an array of photovoltaic panels using high-order neural networks is proposed. First data on the environmental conditions and power generation are processed. From these data a model of the behavior of the photovoltaic array is raised. Finally by an error criterion, the previous model was validated. This model will serve to meet the power to hand depending on weather and substantiate optimization models power generation system conditions. The result of this work is important because the estimated data can be used to improve performance under changing temperature conditions.

ÍNDICE

RESUMEN	ii
ABSTRACT	iii
ÍNDICE	iv
Lista de tablas	vi
Lista de figuras	vii
1. INTRODUCCIÓN	1
1.1 Antecedentes	1
1.2 Planteamiento del problema	6
1.3 Objetivos	6
1.3.1 Objetivo general	6
1.3.2 Objetivos específicos	6
1.4 Preguntas de investigación	7
2. MARCO TEÓRICO	8
2.1 Energías renovables	8
2.2 Series de tiempo	21
2.3 Modelo matemático del arreglo fotovoltaico	24
2.4 Redes neuronales artificiales	30
2.5 Entrenamiento por el Filtro Extendido de Kalman	42
3. METODOLOGÍA	45
3.1 Muestreo de datos	45
3.2 Cálculo de la dimensión de la serie de tiempo	55
4. RESULTADOS	58

4.1 Perceptrón multicapa	60
4.2 Red neuronal de alto orden.....	73
4.3 Análisis comparativo de resultados.....	79
5. ASPECTOS DE IMPLEMENTACIÓN	81
6. CONCLUSIONES	83
REFERENCIAS.....	86

Lista de tablas

Tabla 3.1.1	Correlación entre las mediciones	49
Tabla 3.1.2	Coeficientes de correlación de variables a emplear	50
Tabla 3.1.3	Retrasos de tiempo significativos	54
Tabla 4.1.1	Casos para perceptrón multicapa	60
Tabla 4.1.2	Resumen de parámetros y resultados para perceptrón multicapa	72
Tabla 4.2.1	Errores en la predicción de red neuronal recurrente de alto orden	76
Tabla 4.2.2	Errores en la predicción de red neuronal de alto orden.....	79
Tabla 4.3.1	Evaluación del error para diferentes modelos	80

Lista de figuras

Figura 1.1.1 Sistema de predicción de potencia	4
Figura 1.1.2 Evolución del error de aprendizaje	5
Figura 2.1.1 Aprovechamiento energía solar mediante módulos fotovoltaicos	9
Figura 2.1.2 Aprovechamiento de energía eólica mediante aerogeneradores	9
Figura 2.1.3 Aprovechamiento de energía hidráulica mediante represa	10
Figura 2.1.4 Aprovechamiento de energía geotérmica mediante planta	11
Figura 2.1.5 Ciclo de biomasa.....	11
Figura 2.1.6 Diferentes lingotes de silicio.....	12
Figura 2.1.7 Diagrama de bandas para distintos materiales	13
Figura 2.1.8 Unión p-n de silicio.....	15
Figura 2.1.9 Bandas de energía de unión p-n de silicio	16
Figura 2.1.10 Celda solar de silicio policristalino de primera generación	16
Figura 2.1.11 Celda solar CIGS de segunda generación	17
Figura 2.1.12 Celda solar multiunion de tercera generación de silicio amorfo y arseniuro de galio.....	17
Figura 2.1.13 Eficiencia y costo para las tres generaciones de celdas solares.....	18
Figura 2.1.14 Mejores eficiencias de celdas de investigación	20
Figura 2.2.1 Serie de tiempo	21
Figura 2.3.1 Circuito equivalente para un módulo solar fotovoltaico	24
Figura 2.3.2 Curvas típicas I-V y P-V para un módulo fotovoltaico	25
Figura 2.3.3 Curvas I-V para un módulo FV a diferentes niveles de radiación solar. .	26

Figura 2.3.4. Curva I-V y puntos de máxima potencia de módulo FV a temperaturas de 0 °C y 75 °C.....	27
Figura 2.4.1 Modelo de una neurona artificial	31
Figura 2.4.2 Función de activación escalón	33
Figura 2.4.3 Función de activación sigmoide logística	34
Figura 2.4.4 Función de activación lineal a tramos	34
Figura 2.4.5: Función de activación sigmoide tangente hiperbólica	35
Figura 2.4.6 Red neuronal unicapa	36
Figura 2.4.7 Red neuronal multicapa	36
Figura 2.4.8 Red neuronal recurrente sin autolazos y sin neuronas ocultas	37
Figura 2.4.9 Red neuronal recurrente con neuronas ocultas	37
Figura 2.4.10 Red Neuronal Artificial unidireccional	38
Figura 2.4.11 Red neuronal artificial recurrente	38
Figura 2.4.12 Red neuronal perceptrón multicapa	40
Figura 2.4.13 Red neuronal de segundo orden.....	41
Figura 2.5.1 Esquema de funcionamiento del filtro de Kalman como entrenamiento a la red neuronal	44
Figura 3.1.1 Arreglo de módulos solares fotovoltaicos.....	45
Figura 3.1.2 Estación meteorológica.....	46
Figura 3.1.3 Mediciones de potencia.....	47
Figura 3.1.4 Mediciones de radiación solar.....	47
Figura 3.1.5 Mediciones de temperatura.....	48
Figura 3.1.6 Mediciones de humedad	48

Figura 3.1.7	Correlaciones cruzadas para potencia con radiación solar	51
Figura 3.1.8	Correlaciones cruzadas para potencia con temperatura	52
Figura 3.1.9	Correlaciones cruzadas para potencia con velocidad de viento.....	53
Figura 3.1.10	Correlaciones cruzadas para potencia con humedad	54
Figura 3.2.1	Resultado de aplicar el método de Cao a la serie de tiempo de potencia	57
Figura 4.1.1	Estructura de red neuronal perceptrón multicapa	60
Figura 4.1.2	Resultados perceptrón multicapa caso 1.1	61
Figura 4.1.3	Resultados perceptrón multicapa caso 1.3	61
Figura 4.1.4	Resultados perceptrón multicapa caso 2.3	62
Figura 4.1.5	Resultados perceptrón multicapa caso 2.9	63
Figura 4.1.6	Resultados perceptrón multicapa caso 3.1	64
Figura 4.1.7	Resultados perceptrón multicapa caso 3.9	64
Figura 4.1.8	Resultados perceptrón multicapa caso 4.3	65
Figura 4.1.9	Resultados perceptrón multicapa caso 4.9	66
Figura 4.1.10	Resultados perceptrón multicapa caso 5.3	67
Figura 4.1.11	Detalle de predicción perceptrón multicapa caso 5.3	67
Figura 4.1.12	Resultados perceptrón multicapa caso 5.6	68
Figura 4.1.13	Detalle de predicción perceptrón multicapa caso 5.6	68
Figura 4.1.14	Resultados perceptrón multicapa caso 6.1	69
Figura 4.1.15	Resultados perceptrón multicapa caso 6.6	70
Figura 4.1.16	Resultados perceptrón multicapa caso 6.8	70
Figura 4.2.1	Red neuronal de alto orden recurrente diseñada	73

Figura 4.2.2	Resultado de red neuronal recurrente de alto orden caso 1	74
Figura 4.2.3	Resultado de red neuronal recurrente de alto orden caso 2	74
Figura 4.2.4	Resultado de red neuronal recurrente de alto orden caso 3	75
Figura 4.2.5	Resultado de red neuronal recurrente de alto orden caso 4	75
Figura 4.2.6	Resultado de red neuronal recurrente de alto orden caso 5	76
Figura 4.2.7	Resultado de red neuronal alto orden caso 1.....	77
Figura 4.2.8	Resultado de red neuronal alto orden caso 2.....	77
Figura 4.2.9	Resultado de red neuronal alto orden caso 3.....	78
Figura 4.2.10	Resultado de red neuronal alto orden caso 4.....	78
Figura 5.1.1	Diagrama de implementación.....	81

1. INTRODUCCIÓN

1.1 Antecedentes

Actualmente el empleo de energías alternativas se ha convertido en una prioridad prácticamente para todos los países, debido al inminente agotamiento de los combustibles fósiles y el incremento de la demanda energética. Se estima que para el año 2030 las energías renovables representarán el 30% en la estructura total de energía mientras que la generación de energía fotovoltaica será de más del 10% de la energía total demandada en el mundo.

Los sistemas fotovoltaicos son una tecnología que aplica el efecto foto eléctrico en materiales semiconductores para convertir la energía radiante en energía eléctrica. La tecnología fotovoltaica (PV) es un tipo de energía renovable crucial para muchos países, debido a que la radiación solar está disponible en un alto porcentaje del día.

En años recientes, esta tecnología ha tenido un rápido desarrollo, debido a beneficios como: poco mantenimiento, durabilidad y el apoyo de los diversos gobiernos. Sin embargo, la salida de potencia de los sistemas fotovoltaicos es un proceso no disponible en la totalidad del tiempo.

El estudio sobre la producción de energía a partir de fuentes fotovoltaicas es necesario ya que se tienen y se prevén grandes sistemas de producción de electricidad mediante el uso de la energía solar, además estos sistemas tendrán un gran impacto en los sistemas de energía existentes.

La previsión de potencia de salida de los sistemas fotovoltaicos es una tarea difícil, debido a la alta dependencia de las condiciones externas, como las características de irradiancia, el tiempo solar y la temperatura, los cambios de temperatura influyen en la eficiencia del panel de manera significativa; por lo tanto, tener un modelo que represente esta influencia es importante para el análisis de optimización en la

generación. Con el continuo incremento de velocidad de cálculo de los sistemas computacionales, los investigadores proponen una serie de modelos de predicción de potencia en base a estadísticas complejas y técnicas de inteligencia artificial.

Existen varios enfoques para predecir la potencia de salida del sistema fotovoltaico, como el modelo de predicción basado en la insolación. Este modelo es considerado como el método más eficaz en aplicaciones prácticas, sin embargo, requiere una gran cantidad de parámetros meteorológicos y topográficos para resolver las ecuaciones diferenciales que lo componen, y la aplicación de la presente técnica es costosa (Yona et al., 2007).

Con el fin de superar todos estos problemas, es necesario disponer de una técnica de predicción fiable que sea poco costosa y fácil de usar. La inteligencia artificial (IA), tal como las redes neuronales artificiales (RNAs), son métodos que han ganado más importancia en el campo de la predicción debido a su capacidad para hacer frente a sistemas altamente no lineales y dependientes de muchos parámetros. Las redes neuronales están capacitadas para superar las limitaciones de los enfoques estadísticos y para resolver problemas complejos.

La sencillez, precisión y practicidad son las principales ventajas de los modelos de RNAs desarrollados cuando una cantidad suficiente de los datos experimentales está disponible para estimar la energía fotovoltaica producida. Dentro de los diversos problemas donde se aplican las redes neuronales podemos encontrar áreas muy diversas como modelado, predicción, clasificación y control. Por ejemplo, Mannarino et al. (2015) empleó redes neuronales recurrentes en tiempo discreto para identificar las cargas mecánicas en un aspa NACA 64A010 para uso aéreo. Grahovac et al. (2016) modeló y predijo la producción de bioetanol a partir de intermedios y subproductos del procesamiento de la remolacha azucarera mediante redes neuronales. Rafael et al. (2016) propuso una estrategia de enrutamiento multi-copia que utiliza una versión mejorada del predictor de contactos mediante redes neuronales artificiales, esto aplicado al sistema de transporte de autobuses urbanos que son entornos de comunicación interrumpida e intermitente. Baklacioglu, (2016) diseñó una topología de red neuronal optimizada mediante algoritmos genéticos para predecir el

flujo de combustible-velocidad de un avión de transporte a partir de datos de vuelo reales. Las técnicas han demostrado ser más beneficiosas que los modelos clásicos, específicamente desde el punto de vista de la simplicidad y precisión.

Pedro y Coimbra (2012) desarrollaron y entrenaron varios modelos de predicción para prever la potencia producida para 1 y 2 horas hacia adelante en el tiempo, de una planta de energía fotovoltaica 1 MWp. El objetivo de este trabajo fue estudiar varios de los métodos de previsión más populares y evaluar su exactitud, con el fin de determinar un nivel de rendimiento mínimo para comparar con otros métodos de pronóstico más complejos (usando una variedad de factores meteorológicos y radiométricos como entrada). Cinco métodos diferentes para pronosticar la salida de energía de la planta de energía fotovoltaica 1 MWp, 1 y 2 h antes de tiempo se utilizan en este trabajo. Para ello emplearon los siguientes métodos: modelo persistente, promedio móvil integrado autor regresivo (ARIMA), k-vecinos más cercanos (kNNs), RNAs y un método híbrido de algoritmos genéticos (AG) aplicado a redes neuronales artificiales (RNAs). Para tales modelos se asumen condiciones de cielo claro. El análisis de los resultados mostró que los dos métodos basados en RNA, la RNA y la AG/RNA superan claramente a los otros modelos. Los resultados basados en RNAs demostraron que la selección de datos de entrada y la arquitectura inicial fue sub óptima.

Leva et al. (2015) desarrolló un modelo de predicción de potencia de un sistema fotovoltaico de 24 horas hacia adelante en el tiempo mostrado en la Figura 1.1.1, basado en RNAs acompañado de un modelo de cielo despejado para la validación de datos de entrada para el día siguiente, con el objetivo de evaluar la sensibilidad mediante el cambio del tamaño del grupo de datos para entrenamiento, el número de iteraciones y una o múltiples ejecuciones. Este análisis está basado en actividades experimentales de una planta real de energía fotovoltaica. Se hace un análisis de validación de los datos históricos medidos. Es empleado el modelo clásico llamado perceptrón multicapa (MLP), con retropropagación del error (EBP) como procedimiento de entrenamiento. Las entradas son variables meteorológicas, coordenadas geográficas del sitio, la hora y día para calcular la posición del Sol. La RNA está desarrollada con las siguientes características: 9 neuronas en la primera capa, 7

neuronas en la segunda capa y 3000 iteraciones para cada prueba. Estas características son el resultado de estudios previos del autor que han probado ser buenas en términos de eficiencia y tiempo computacional. Durante el entrenamiento de la red, se ordenó el conjunto de datos de acuerdo con el índice de claridad diario, para clasificar los datos de entrada en tres diferentes tipos de día: soleado, parcialmente nublado y nublado. Las tendencias de los errores muestran como la precisión en días soleados es mayor, mientras que en días parcialmente nublados y nublados la eficiencia global es ligeramente diferente.

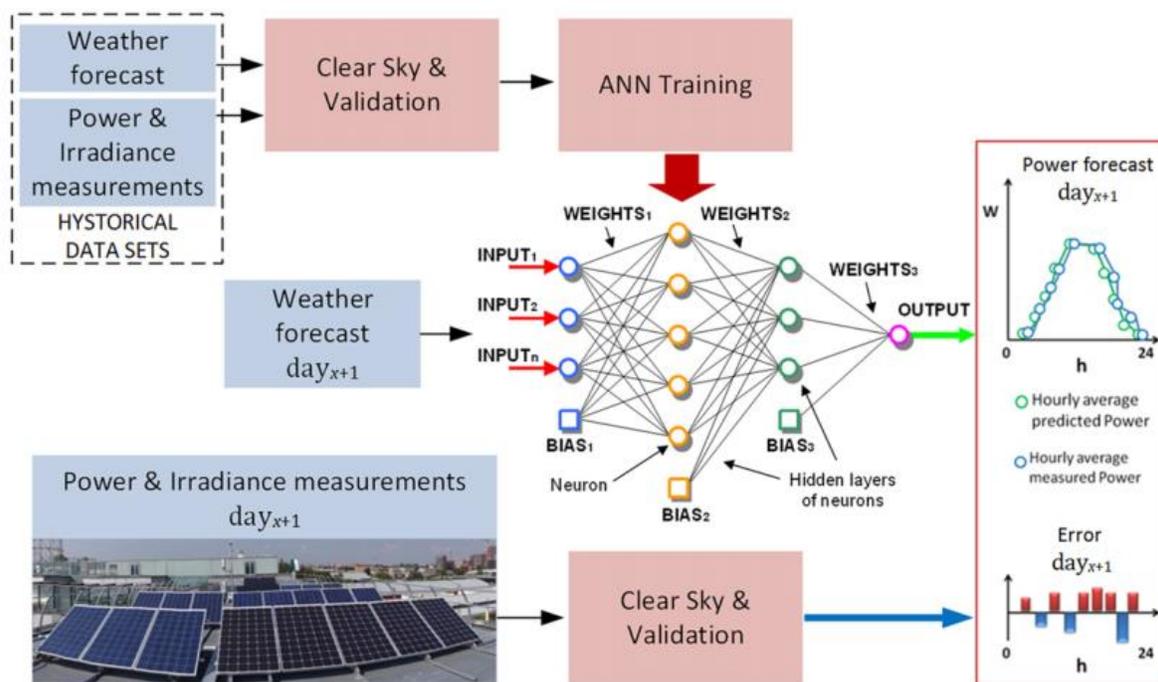


Figura 1.1.1: Sistema de predicción de potencia (Leva et al. (2015)).

Dumitru (2016) analizó la posibilidad de usar un perceptrón multicapa (MLP) y una red neuronal de Elman para predecir la producción de energía de una fuente fotovoltaica. El número de capas ocultas del MLP no está limitado, sin embargo, algunos estudios han encontrado que en la mayoría de los problemas prácticos es suficiente usar un máximo de dos capas ocultas. Un papel importante en las prestaciones de la red neuronal se asigna a la ley de aprendizaje. En este caso, se adoptó un algoritmo de optimización de gradiente descendente (retropropagación). Las redes de tipo Elman son las más simples de los modelos recurrentes y para este caso, emplean el mismo

algoritmo de aprendizaje que el modelo MLP. Se encontraron diferencias notables entre las dos estructuras consideradas. En la etapa de aprendizaje la red neuronal de tipo Elman, con un pequeño conjunto de datos de prueba se comportó mejor que el MLP como se ve en la Figura 1.1.2 (MLP curva roja, red neuronal de tipo Elman curva verde). Este comportamiento mejorado se manifestó en el decremento del error y un menor número de épocas. En el caso de una gran cantidad de datos, los papeles se invirtieron, pero la diferencia no es tan notable. Dependiendo del tipo de datos y la complejidad de la red neuronal, es posible elegir entre un modelo y otro. Un incremento en la precisión de la predicción puede ser alcanzado considerando varios factores como son la época del año, las condiciones meteorológicas y la posibilidad de extender el conjunto de datos a un mayor número de años.

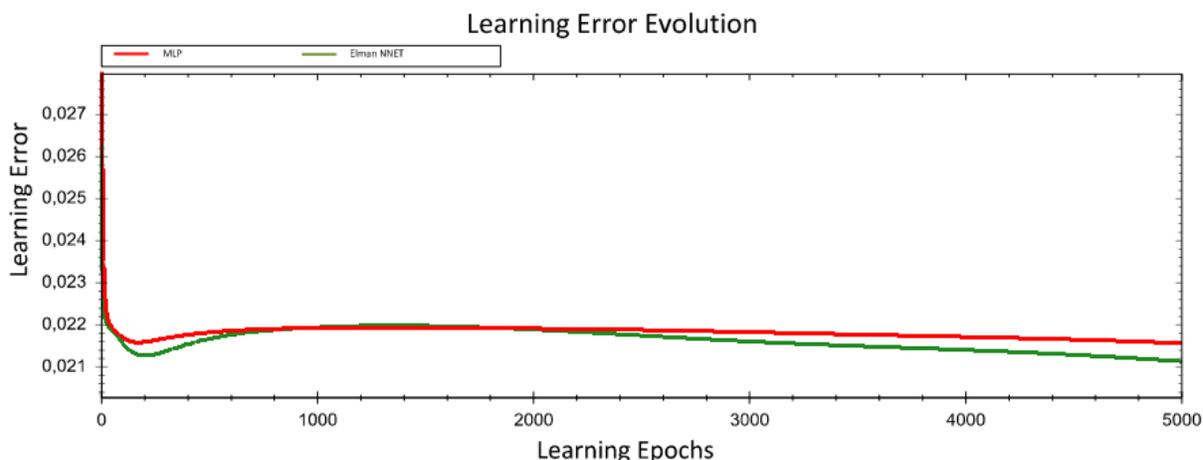


Figura 1.1.2: Evolución del error de aprendizaje (Dumitru 2016).

Una predicción exacta de energía fotovoltaica es útil para optimizar estrategias económicas, maximizar beneficios, así como para la planificación general de mantenimiento. Por ejemplo, los modelos generados mediante RNAs pueden ser empleados para detectar fallas en los arreglos fotovoltaicos basándose en las pérdidas de potencia (mediante una comparación entre la potencia medida y la potencia predicha), y a partir de este análisis detectarse qué tipo de fallo ocurre (efecto de sombra, degradación de los módulos, acumulación de polvo etc.). Este tipo de aplicación es más benéfica para sistemas fotovoltaicos de gran escala, como plantas de energía solar.

1.2 Planteamiento del problema

En este trabajo de investigación se propone la obtención de un modelo matemático para la generación de potencia de un arreglo de paneles fotovoltaicos usando redes neuronales de alto orden. Primero se procesarán datos de las condiciones ambientales y generación de potencia. A partir de estos datos se planteará un modelo del comportamiento del arreglo fotovoltaico. Finalmente, mediante un criterio de error, se validará el modelo previo. Este modelo servirá para conocer la potencia que entregará el sistema dependiendo de las condiciones climáticas y fundamentará modelos de optimización de la generación de energía. El resultado de este trabajo es importante debido a que los datos estimados pueden ser utilizados para mejorar el desempeño del arreglo modificando las condiciones de temperatura.

1.3 Objetivos

1.3.1 Objetivo general

Diseñar e implementar un algoritmo de predicción de potencia de un arreglo de paneles fotovoltaicos basado en redes neuronales de alto orden entrenadas por el filtro de Kalman para un horizonte de por lo menos 6 pasos en el tiempo.

1.3.2 Objetivos específicos

- Identificar las variables meteorológicas relacionadas con las características eléctricas de los arreglos de paneles fotovoltaicos.
- Obtener y estructurar una base de datos de mediciones de datos reales que sean útiles para el modelado.

- Diseñar las arquitecturas neuronales que minimicen el error de predicción de la potencia de un arreglo de paneles fotovoltaicos.
- Desarrollar los métodos de entrenamiento utilizando el filtro extendido de Kalman.
- Diseñar e implementar un simulador en el entorno de MATLAB® con el algoritmo de predicción de potencia de un arreglo fotovoltaico.
- Validar y comparar los resultados de la predicción de la serie de tiempo de la potencia del arreglo de paneles fotovoltaicos con otros algoritmos documentados en la literatura.

1.4 Preguntas de investigación

¿Cuáles son las variables ambientales de mayor impacto en la producción de energía eléctrica de un arreglo fotovoltaico?

¿Cuál estructura de red neuronal es apropiada para modelar y analizar la eficiencia a de la generación de un arreglo fotovoltaico?

2. MARCO TEÓRICO

2.1 Energías renovables

Con la creciente importancia de los problemas ambientales, la generación de energía limpia se vuelve dominante en todos los aspectos del uso de la energía. Los combustibles fósiles y otros deben ser sustituidos por energías limpias y respetuosas con el medio ambiente. Las fuentes de energía renovables son aquellas que, tras ser utilizadas, se pueden regenerar de manera natural o artificial. Algunas de estas fuentes renovables están sometidas a ciclos que se mantienen de forma más o menos constante en la naturaleza. A continuación, se mencionan los tipos de energía renovable más comunes.

- **Energía solar:** se basa en la radiación solar que llega a la superficie de la tierra. El consumo total de energía en nuestro planeta, basado en el uso de formas convencionales de energía como el petróleo, carbón, electricidad u otras, representa alrededor de 1% del total de la energía solar que llega a la superficie de nuestro planeta. El uso de sistemas fotovoltaicos es el área más estudiada de las energías renovables, ya que ofrece varias ventajas, como la prevención de la contaminación atmosférica, el funcionamiento silencioso como consecuencia de la inmovilidad y la reducción de costes de mantenimiento. (Kabalci y Kalbaci, 2017). El transporte de electrones debido a la radiación solar incidente en un material semiconductor es denominado efecto fotoeléctrico. Este efecto permite la excitación de los átomos de silicio permitiendo el libre flujo de electrones y la generación de energía eléctrica. Se muestra en la Figura 2.1.1 el aprovechamiento de la energía solar mediante un módulo fotovoltaico.



Figura 2.1.1: Aprovechamiento energía solar mediante módulos fotovoltaicos.

- **Energía eólica:** consiste en la conversión de la energía cinética del viento, por medio de aerogeneradores, en energía eléctrica. El viento mueve las aspas, que, a su vez, transmiten su potencia hacia las turbinas haciendo mover los generadores que producen energía eléctrica, como se muestra en la Figura 2.1.2. El principio aerodinámico, por el cual, el conjunto de aspas gira es similar al que hace que los aviones vuelen. Según este principio, el aire es obligado a fluir por las caras superior e inferior de un perfil inclinado, generando una diferencia de presión entre ambas caras y dando lugar a una fuerza resultante que actúa sobre el perfil (Henestroza, 2009).



Figura 2.1.2: Aprovechamiento de energía eólica mediante aerogeneradores.

- **Energía hidráulica:** aprovecha la energía cinética y potencial de las corrientes de ríos, saltos de agua o mareas. Es, quizás, la forma más antigua de aprovechamiento de energía para el desarrollo de las actividades productivas de la humanidad (Posso, 2002). Este tipo de energía se considera renovable cuando su aprovechamiento se realiza con una potencia no superior a 10MW. La energía hidráulica que supera esta potencia no se considera renovable debido al gran impacto ambiental de su emplazamiento para una mayor producción. En la Figura 2.1.3 se observa una represa de energía renovable.



Figura 2.1.3: Aprovechamiento de energía hidráulica mediante represa.

- **Energía geotérmica:** Las rocas que se encuentran en las profundidades del planeta están a temperaturas muy elevadas. La energía calórica almacenada en esas rocas se conoce como energía geotérmica. Se puede encontrar en forma de vapor (géiser), en forma de gases de alta temperatura (fumarolas) y en forma de agua caliente (fuentes termales). Esta energía puede ser de tres tipos: baja, media y alta temperatura. La primera es de uso doméstico, la energía que se recoge se emplea en calefacción y en producción de agua caliente. Las otras dos se usan para producir electricidad mediante plantas geotérmicas (Robilliard, 2009). Se muestra en la Figura 2.1.4. una planta geotérmica.



Figura 2.1.4: Aprovechamiento de energía geotérmica mediante planta.

- Biomasa:** engloba toda la materia orgánica que se encuentra disponible en una base renovable, en un área determinada de la superficie terrestre, o por organismos de un tipo específico. Abarca desde todo tipo de cultivos hasta los posibles desechos generados, ya sean de origen animal o vegetal. Desde el punto de vista industrial, como materia prima se incluyen también los cultivos de plantas acuáticas y los residuos orgánicos potencialmente revalorizables en procesos industriales, como los aceites usados (Quesada et al., 2014). Cuando hablamos de energía de biomasa nos referimos al combustible energético que se obtiene directa o indirectamente de recursos biológicos (Figura 2.1.5).

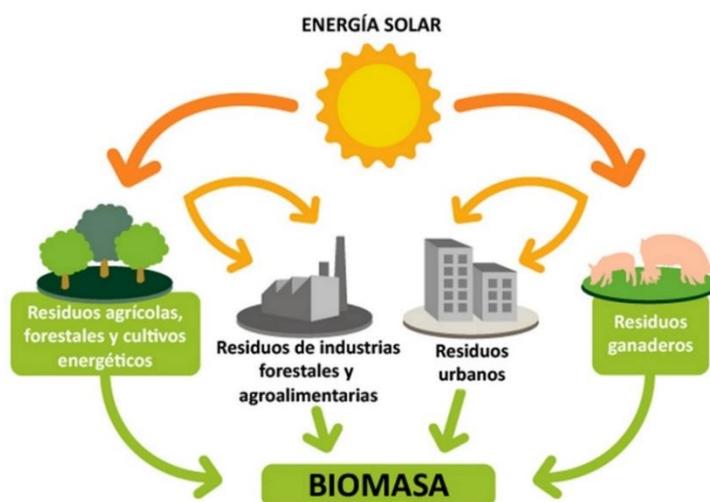


Figura 2.1.5: Ciclo de la biomasa.

Las siguientes paginas cubren los aspectos básicos de los materiales semiconductores y los mecanismos físicos que ocurren en el interior de los dispositivos fotovoltaicos. Estos mecanismos se utilizan para explicar el funcionamiento de una unión (juntura) p-n, que forma la base no sólo para la gran mayoría de las celdas solares, sino también para la mayoría de otros dispositivos electrónicos, tales como los láseres y los transistores de unión bipolares. Mientras que los materiales semiconductores fotovoltaicos no se limitan a silicio, el predominio de silicio en el mercado fotovoltaico ha llevado a nuestro énfasis particular de este material. Un lingote de silicio (Figura 2.1.6), consiste de un solo cristal grande de silicio. Un lingote de este tipo se corta en obleas individuales y luego se usa para hacer una variedad de dispositivos semiconductores, incluyendo las celdas solares y los chips de computadora.



Figura 2.1.6: Diferentes lingotes de silicio.

Los materiales semiconductores vienen de diferentes grupos en la tabla periódica, pero comparten ciertas similitudes. Las propiedades del material semiconductor están relacionadas con sus características atómicas, y cambian de grupo a grupo. Los investigadores y diseñadores aprovechan estas diferencias para mejorar el diseño y elegir el material óptimo para una aplicación fotovoltaica.

Los parámetros más importantes de un material semiconductor para la operación de celdas solares son:

- La banda prohibida (band gap).
- El número de portadores libres (electrones) disponibles para la conducción.
- La "generación" y la recombinación de portadores libres (electrones) en respuesta a la luz que brilla sobre el material.

El nivel de energía más bajo de un semiconductor se denomina "banda de valencia" (EV) y el nivel de energía al que un electrón puede considerarse libre se denomina "banda de conducción" (EC). La banda prohibida (EG) es la brecha de energía entre el estado ligado y el estado libre. Por lo tanto, la banda prohibida es el cambio mínimo en la energía requerida para excitar el electrón para que pueda participar en la conducción (Kittel, 2005). Se muestra el diagrama de bandas para diferentes materiales en la Figura 2.1.7.

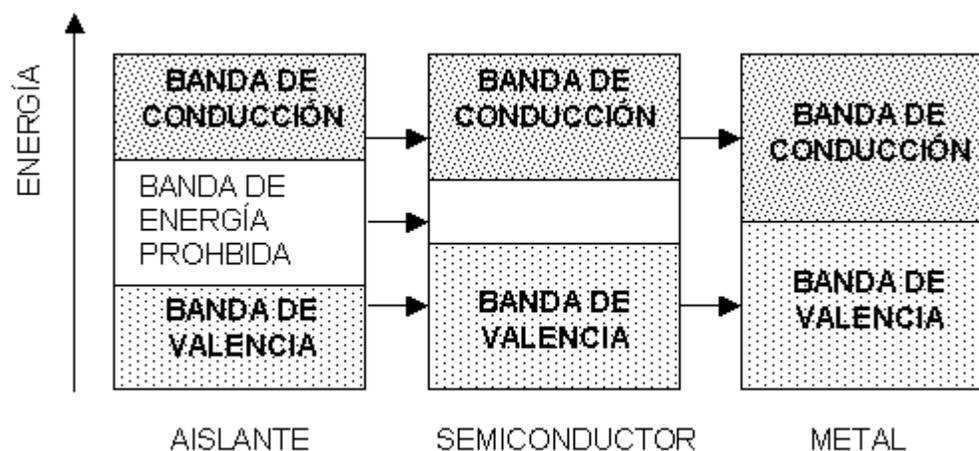


Figura 2.1.7: Diagrama de bandas para distintos materiales.

La excitación de un electrón a la banda de conducción deja atrás un espacio vacío para un electrón. Un electrón de un átomo vecino puede moverse dentro de este espacio vacío. Cuando este electrón se mueve, deja atrás otro espacio. El movimiento continuo del espacio para un electrón, llamado "agujero" o "hueco", puede ser ilustrado como el movimiento de una partícula cargada positivamente a través de la estructura cristalina.

Por consiguiente, la excitación de un electrón en la banda de conducción da como resultado no sólo un electrón en la banda de conducción, sino también un agujero en la banda de valencia. Así, tanto el electrón como el agujero pueden participar en la conducción y son llamados "portadores".

La excitación térmica de un portador de la banda de valencia a la banda de conducción crea portadores libres en ambas bandas. La concentración de estos portadores se denomina concentración portadora intrínseca, denotada por n_i , esta es una cantidad fundamental en la física de semiconductores, que entra en casi todos los cálculos que relacionan las respuestas con las excitaciones (Altermatt et al., 2003). El material semiconductor que no ha tenido impurezas añadidas a él para cambiar las concentraciones de portadores se llama material intrínseco. La concentración intrínseca de portadores es el número de electrones en la banda de conducción o el número de agujeros en la banda de valencia en material intrínseco. Este número de portadores depende del espacio de banda del material y de la temperatura del material. Un gran espacio de banda hará más difícil que un portador sea excitado térmicamente a través del espacio de banda, y por lo tanto la concentración intrínseca del portador es menor en materiales con un intervalo de banda más alto. Alternativamente, el aumento de la temperatura hace que sea más probable que un electrón sea excitado dentro de la banda de conducción, lo que aumentará la concentración intrínseca del portador. Esto se traduce directamente en la eficiencia de las celdas solares.

Las uniones p-n se forman uniendo materiales semiconductores de tipo n (dopados negativamente) y p (dopados positivamente), la unión se comporta de manera muy diferente a como lo hacen cada uno de los materiales por si solos.

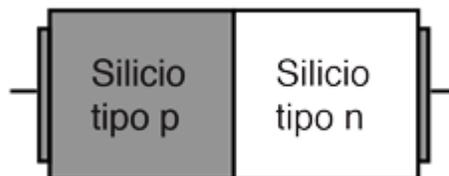


Figura 2.1.8: Unión p-n de silicio.

El croquis de nivel de energía (Figura 2.1.9), es una forma de visualizar la condición de equilibrio de la unión p-n. La dirección ascendente en el diagrama representa la energía reciente de electrones. Los círculos vacíos en el lado izquierdo de la unión, representan "huecos". Los círculos sólidos a la derecha de la unión representan los electrones disponibles desde el dopante de tipo n. Cerca de la unión, los electrones se difunden a través de la unión p-n y se combinan con los agujeros, creando una "región de depleción" y un campo eléctrico.

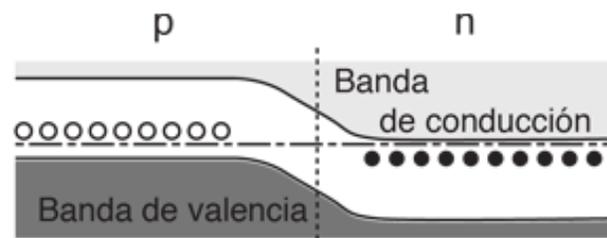


Figura 2.1.9: Bandas de energía unión p-n de silicio.

El siguiente es el proceso básico, repetido millones de veces, que permite a una celda solar generar energía eléctrica (Würfel, 2005):

1. Los fotones inciden en la superficie de la celda, usualmente de vidrio, y este permite pasar la luz a la capa del semiconductor tipo n.
2. Los átomos en la capa del semiconductor tipo n se excitan liberando electrones, lo que genera un exceso de electrones en la misma.
3. La capa de semiconductor tipo p tiene una deficiencia de electrones, lo cual atrae a los electrones excitados provenientes de la capa tipo n. En términos eléctricos, se genera una diferencia de potencial entre ambas capas del semiconductor, mejor conocido como voltaje.
4. Los electrones viajan del semiconductor tipo n al p a través del punto de unión entre ambos. Esto genera un campo eléctrico en la unión, y esta es la corriente eléctrica que se aprovecha de la celda.

Las celdas fotovoltaicas se clasifican en tres generaciones que indican el orden de importancia y relevancia que han tenido históricamente (Huerta, 2014). En el presente existe investigación sobre las tres generaciones mientras que las tecnologías de la primera generación son las que más están representadas en la producción comercial con el 89.6% de producción en 2007.

Primera generación: Las celdas de la primera generación tienen gran superficie, alta calidad y se pueden unir fácilmente. Las tecnologías de la primera generación no permiten ya avances significativos en la reducción de los costes de producción. Los dispositivos formados por la unión de células de silicio (Figura 2.1.10) se están acercando al límite de eficacia teórica que es del 31% y tienen un periodo de amortización de 5-7 años.

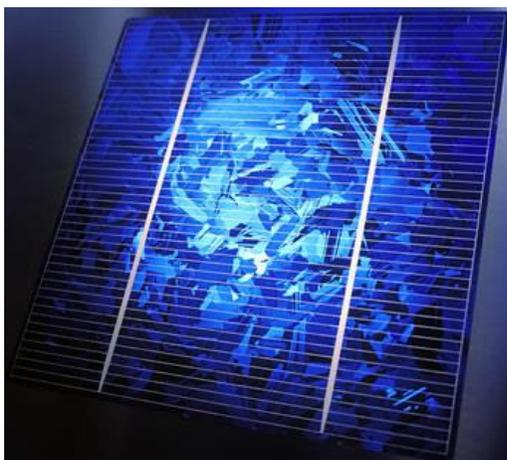


Figura 2.1.10: Celda solar de silicio policristalino de primera generación.

Segunda generación: Los materiales de la segunda generación han sido desarrollados para satisfacer las necesidades de suministro de energía y el mantenimiento de los costos de producción de las celdas solares. Las técnicas de fabricación alternativas, como la deposición química de vapor, y la galvanoplastia tiene más ventajas, ya que reducen la temperatura del proceso de forma significativa. Entre los fabricantes, existe una tendencia hacia las tecnologías de la segunda generación, pero la comercialización de estas tecnologías ha sido difícil. Como se ve en la Figura 2.1.11 se pueden obtener celdas flexibles.



Figura 2.1.11: Celda solar CIGS de segunda generación.

Tercera generación: Se denominan celdas solares de tercera generación a aquellas que permiten eficiencias de conversión eléctrica teóricas mucho mayores que las actuales y a un precio de producción mucho menor. La investigación actual se dirige a la eficiencia de conversión del 30-60%, manteniendo los materiales y técnicas de fabricación a un bajo costo. Se puede sobrepasar el límite teórico de eficiencia de conversión de energía solar para un solo material, que fue calculada como la eficiencia esperada para silicio del orden de 30% a 31%, no utilizándose turbinas ni generador si no la luz natural del sol (Shockley y Queisser, 1961). Existen diversos métodos para lograr esta alta eficiencia incluido el uso de celda fotovoltaica con multijuntura (Figura 2.1.12), la concentración del espectro incidente, el uso de la generación térmica por luz ultravioleta para aumentar la tensión, o el uso del espectro infrarrojo para la actividad nocturna.



Figura 2.1.12: Celda solar multiunion tercera generación de silicio amorfo y arseniuro de galio.

La Figura 2.1.13 muestra la relación entre la eficiencia y costo para las tres generaciones de celdas solares, con líneas de puntos se muestran las trayectorias para diferentes costos por Watt producido. Se observa que la primera generación está llegando a la máxima eficiencia permitida para elementos semiconductores de una sola banda prohibida. La segunda generación tiene costos mucho menores que la primera generación, pero una eficiencia muy baja, esto es debido a la reciente investigación en este campo. La tercera generación ha sobrepasado el límite de una sola banda prohibida y presenta costos menores a las dos anteriores (Conibeer, 2007).

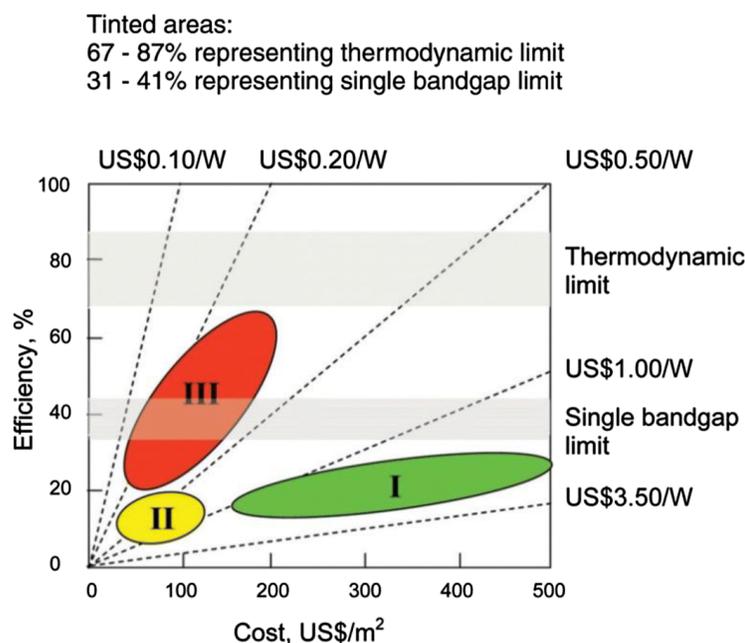


Figura 2.1.13: Eficiencia y costo para las tres generaciones de celdas solares.

El Laboratorio Nacional de Energía Renovable (NREL) mantiene una gráfica de los valores compilados de las mayores eficiencias de conversión confirmadas para las celdas de investigación (Figura 2.1.14), desde 1976 hasta la actualidad, para una gama de tecnologías fotovoltaicas.

Los dispositivos incluidos en esta gráfica del estado actual de la técnica tienen eficiencias que son confirmadas por laboratorios de ensayo independientes y reconocidos (por ejemplo, NREL, AIST, Fraunhofer) y se informan sobre una base estandarizada. Las mediciones para nuevas entradas deben ser con respecto a las Condiciones Estándar de Revisión o Prueba (STC) definidas por el espectro global de

referencia para dispositivos planos y el espectro de referencia directa para dispositivos concentradores que se enumeran en las normas IEC 60904-3 edición 2 o ASTM G173. La temperatura de referencia es de 25 ° C y el área es el área total de la celda o el área definida por una abertura.

Los resultados de eficiencia de las celdas se proporcionan dentro de diferentes familias de semiconductores: (1) celdas multiunion, (2) celdas de arseniuro de galio de una sola unión, (3) celdas de silicio cristalino, (4) tecnologías de película delgada y (5) celdas fotovoltaicas emergentes. Alrededor de 26 subcategorías diferentes se indican con símbolos de colores distintivos.

El récord mundial más reciente para cada tecnología se destaca a lo largo del borde derecho en una bandera que contiene la eficiencia y el símbolo de la tecnología. La empresa o grupo que fabricó el dispositivo para cada registro más reciente está en negrita en la trama.

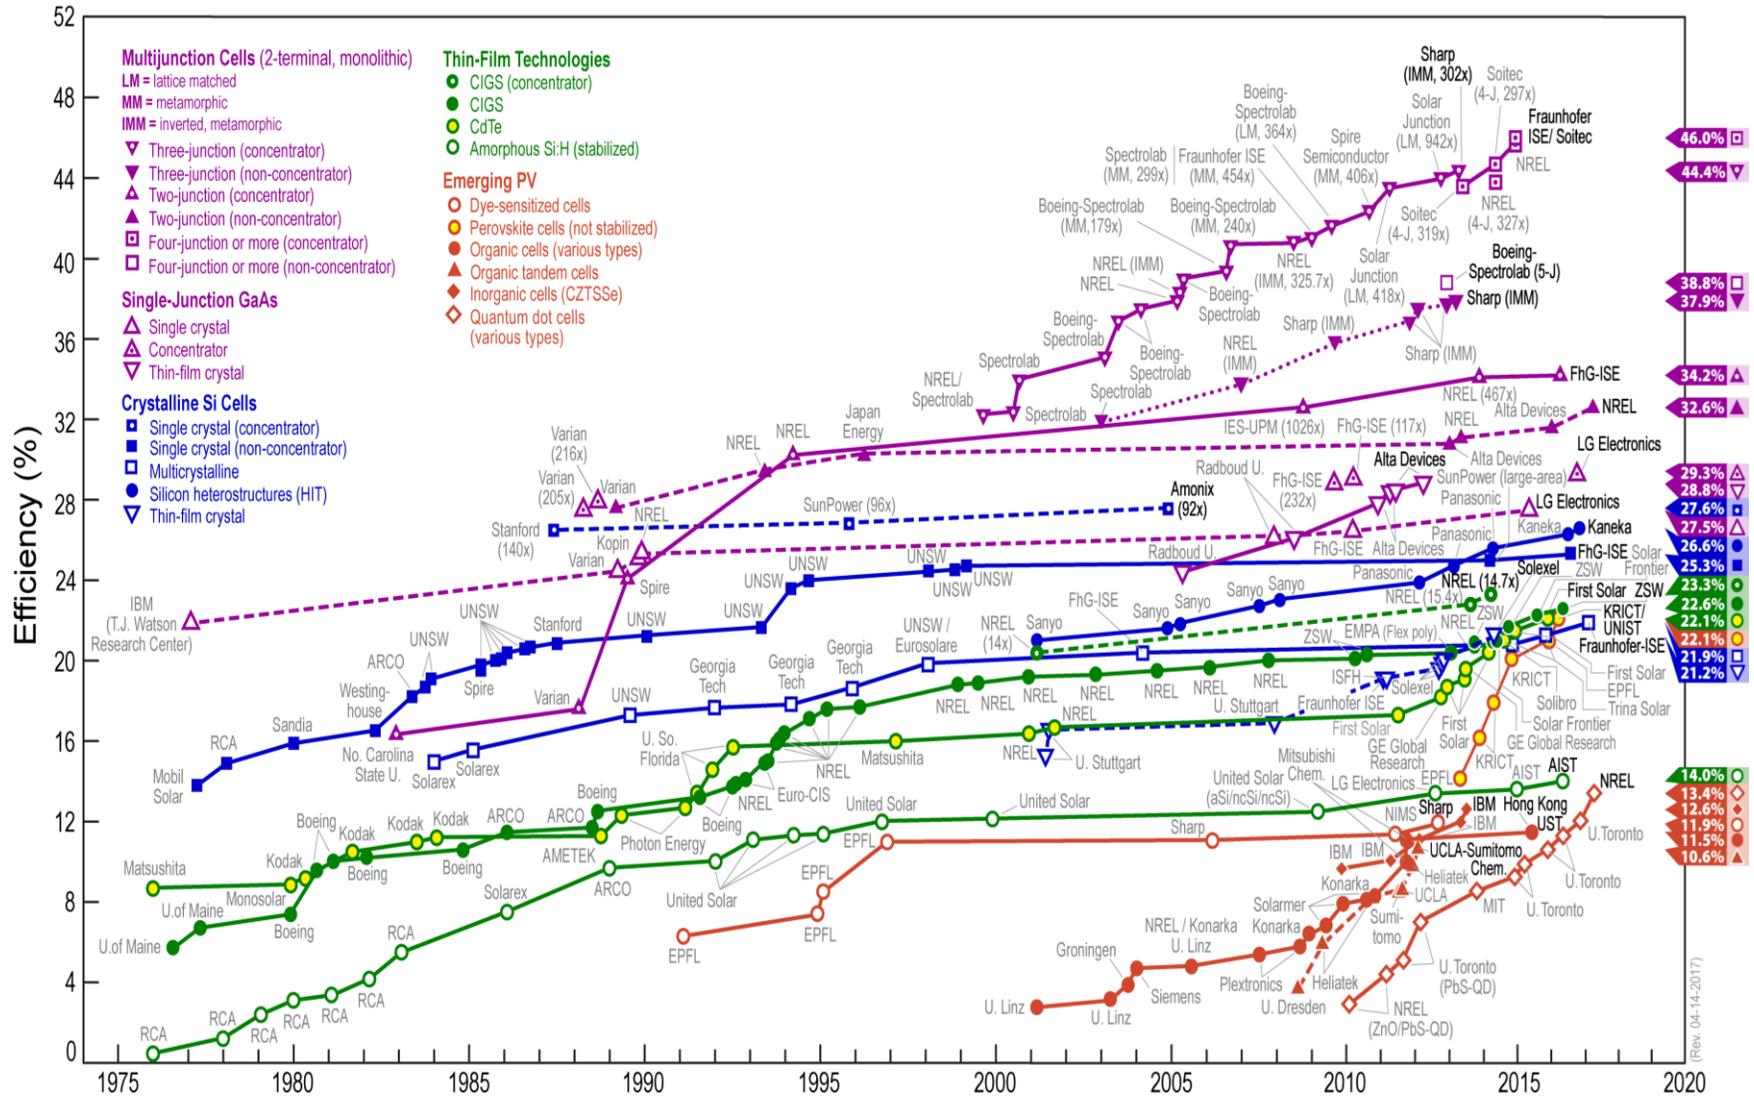


Figura 2.1.14: Mejores eficiencias de celdas de investigación.

2.2 Series de tiempo

Una serie de tiempo es un conjunto de observaciones ordenadas de una variable durante periodos de tiempo sucesivos e iguales. El primero y el más importante de los pasos en el análisis de una serie de tiempo y en el consecuente desarrollo de un modelo de pronóstico es la recolección de datos confiables y válidos.

En las series de tiempo se estudia como una variable cambia a través del tiempo para identificar la relación entre éstos y poder predecir comportamientos en el futuro (Jiménez, 2007). Estas son ampliamente usadas en estadística, finanzas, biología y en otros campos. Básicamente, para cada campo en el cual esté implicado una serie de observaciones, los modelos de series de tiempo pueden ser usados. Los datos históricos se analizan y se descomponen para identificar los componentes que influyen la variable a pronosticar como se muestra en la Figura 2.2.1

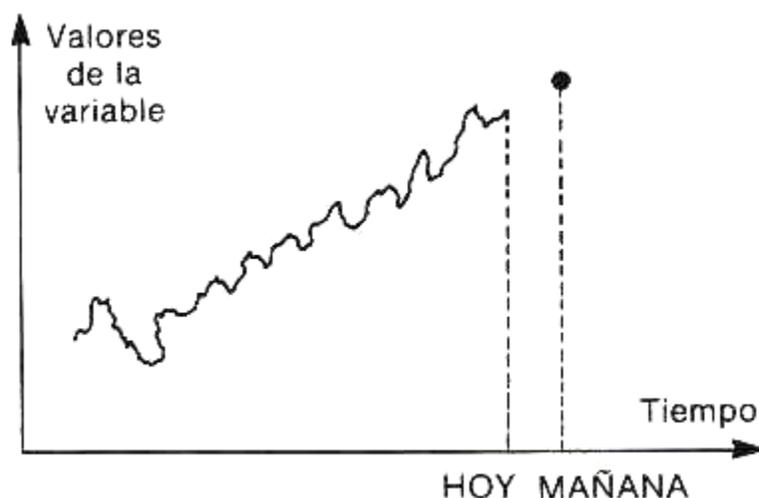


Figura 2.2.1: Serie de tiempo.

Los datos de las series de tiempo generalmente consisten de una combinación de uno o más de los siguientes componentes:

- **Tendencia:** Es un movimiento lineal ascendente o descendente de los datos a lo largo de un periodo de tiempo grande. Identifica la tasa de crecimiento o descenso de una serie a través del tiempo.

- Estacionalidad: Las variaciones estacionales consisten en movimientos recurrentes por encima y por debajo de la línea de tendencia y su patrón se repite año con año.
- Dilucididad: Son las variaciones oscilatorias alrededor de la línea de tendencia que ocurren durante largos periodos de tiempo.
- Variaciones aleatorias: También conocidas como ruido, son las variaciones que no tienen patrones definidos y sus causas no son identificables. Están presentes en todas las series de tiempo y sus efectos forman parte de las desviaciones no explicadas de los datos.

En cuanto al aspecto temporal de las predicciones, es importante introducir tres conceptos: horizonte de pronóstico f_h , resolución de pronóstico f_r e intervalo de pronóstico f_i . El horizonte de pronóstico es la cantidad de tiempo entre el tiempo actual t y el tiempo efectivo de predicciones. La resolución de pronóstico describe la frecuencia con la que se emiten los pronósticos y el intervalo de pronóstico indica el intervalo de tiempo de las predicciones (Antonanzas, 2016).

El propósito principal de mejorar la precisión de la predicción de potencia producida por fuentes fotovoltaicas, es reducir las incertidumbres relacionadas a esta fuente de energía variable, lo que resultaría directamente en una gestión de la red más segura y fácil. Los gerentes de planta también encuentran motivación para emitir mejores predicciones, ya que pueden planificar mejor las paradas de mantenimiento y generar ofertas más precisas. Así, en algunos mercados de electricidad, los productores solares pueden enfrentar penalidades cuando las desviaciones entre la energía proyectada y la producida exceden una banda de tolerancia.

La forma principal en la que se pueden clasificar los pronósticos es según el horizonte temporal. Las predicciones hechas para los diversos horizontes temporales son importantes para diferentes aspectos de la operación de la red.

Pronóstico a muy corto plazo, también denotado como intra-hora o *nowcasting*, cubre horizontes de pronóstico de unos segundos a 1 h. Es importante asegurar la calidad y estabilidad de la red y la respuesta a la demanda. Se convierte en una cuestión crucial cuando se consideran las redes de la isla o sistemas con fuente de alimentación de

baja calidad donde la penetración solar alta está presente. También proporciona beneficios a nivel de operación del sistema de distribución, ya que permite la reducción del número de operaciones de derivación en los transformadores. Sin embargo, los sistemas robustos con plantas fotovoltaicas distribuidas no sufren tanto de la variabilidad de la generación de energía a muy corto plazo, ya que la agregación de la producción en grandes áreas tiende a equilibrar las fluctuaciones.

Los pronósticos intra-día cubren de 1 a 6 h y son importantes para propósitos de carga. Además, son esenciales para operadores de redes que controlan diferentes zonas de carga o que comercian fuera de los límites de su área. Las previsiones de 6 h hasta el día siguiente se utilizan normalmente para la planificación y el compromiso de la unidad, el cual es una gran familia de problemas de optimización matemática en la que la producción de un conjunto de generadores eléctricos se coordina con el fin de lograr algún objetivo común, ya sea que se ajustan a la demanda de energía a un costo mínimo o maximizar los ingresos de la producción de energía. Cubren horizontes de 6 a 48 h, dependiendo de cuándo se emiten los pronósticos.

Las previsiones de 2 días o más se utilizan para el compromiso de la unidad, la gestión de la transmisión, el comercio, la cobertura, la planificación y la optimización de activos. También son importantes para planificar el mantenimiento de la planta de una manera rentable, es decir, cuando la producción esperada es baja. Cubren horizontes de más de 48 horas.

El horizonte de previsión en el que se han realizado la mayor parte de las investigaciones es el día siguiente. La razón de este comportamiento es que la mayor parte de la energía se comercializa en los mercados de día a día, cuando la planificación y el compromiso de la unidad tienen lugar. A medida que los mercados de energía evolucionan, el comercio intra-hora será más importante y, por lo tanto, más investigación se centrará en ese horizonte temporal y con una mayor aplicabilidad en los mercados de electricidad.

2.3 Modelo matemático del arreglo fotovoltaico

El modelo utilizado en (Duffie et al, 2013), presenta un circuito equivalente que se puede utilizar para modelar una celda individual, un módulo fotovoltaico (FV) formado de varias celdas o un arreglo formado de varios módulos. El circuito mostrado en la Figura 2.3.1 requiere el conocimiento de cinco parámetros: La corriente foto generada I_L , la corriente de saturación del diodo I_0 , la resistencia en serie R_S , la resistencia en paralelo R_{Sh} y un parámetro de ajuste a de la curva $I - V$.

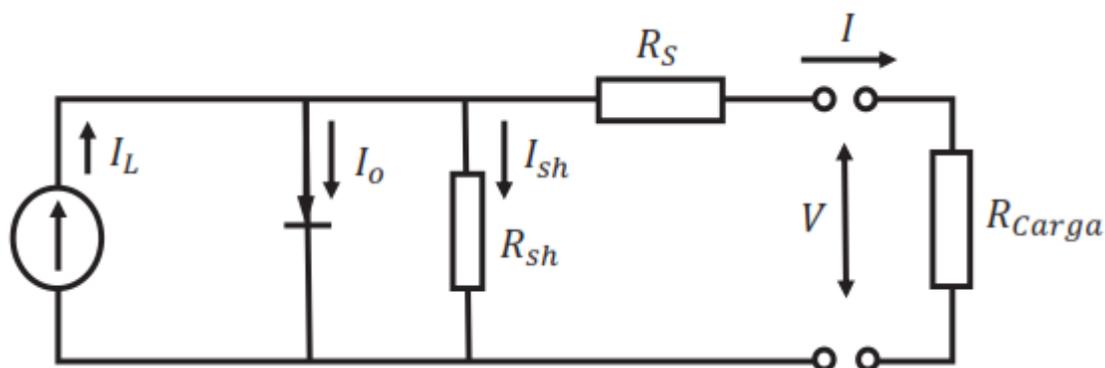


Figura 2.3.1: Circuito equivalente para un módulo solar fotovoltaico.

Para una radiación solar y una temperatura del módulo fijas, la curva característica corriente-voltaje está dada por:

$$I = I_L - I_0 \left[e^{\left(\frac{V + IR_S}{a} \right)} - 1 \right] - \frac{V + IR_S}{R_{Sh}} \quad (3.3.1)$$

Donde I y V son la corriente y el voltaje de operación, respectivamente. La potencia del módulo FV está dada por

$$P = IV \quad (3.3.2)$$

En la Figura 2.3.1, se muestra la curva característica $I - V$, para valores fijos de radiación solar y temperatura de la celda. En esa figura se muestra también la curva de potencia-voltaje $P - V$.

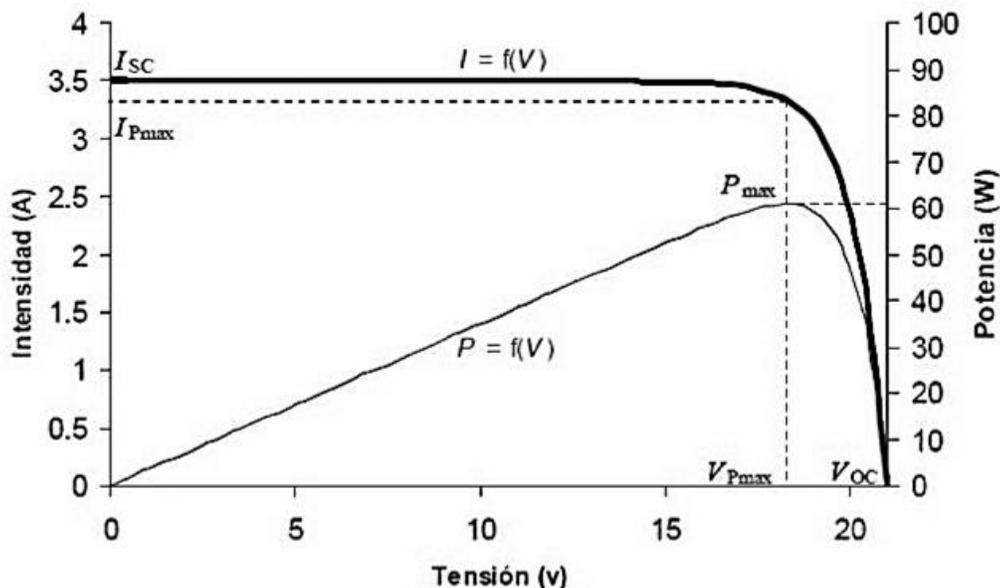


Figura 2.3.2: Curvas típicas I-V y P-V para un módulo fotovoltaico.

El punto en la curva donde $V = 0$ es la corriente de corto circuito I_{SC} , y en la intersección de la curva con el eje V , donde $I = 0$, es el voltaje de circuito abierto V_{OC} . El punto de máxima potencia, marcado como P_{max} en la Figura 2.3.2, la corriente es $I_{P_{max}}$ y el voltaje es $V_{P_{max}}$. Idealmente, la celda opera siempre en el punto de máxima potencia, pero de manera práctica la celda opera en un punto sobre la curva $I - V$ que corresponde a la característica $I - V$ de la carga.

El producto $I_{P_{max}}V_{P_{max}}$ que da la potencia entregada a la carga, está representado en la Figura 2.3.2 por el área del rectángulo marcado con las líneas punteadas, que es menor que la del rectángulo que representa el producto $I_{SC}V_{OC}$ de la mayor corriente que puede extraerse del módulo I_{SC} por el mayor voltaje V_{OC} . Ambos productos se aproximan más, cuanto más pronunciado sea el codo de la curva característica; en todos los casos reales el parámetro definido por el cociente:

$$FF = \frac{I_{P_{max}}V_{P_{max}}}{I_{SC}V_{OC}} \quad (3.3.3)$$

Es siempre menor que la unidad. Este cociente, llamado factor de forma, suele utilizarse como cuantificación de la curva característica.

La radiación solar incidente sobre el módulo fotovoltaico, influye sobre la corriente generada de tal manera que cuando se tiene una mayor radiación solar, la corriente aumenta. En la Figura 2.3.3, se muestran diferentes curvas corriente-voltaje para un módulo operando a temperatura fija y diferentes niveles de radiación. La potencia generada por el módulo FV también se ve afectada por la temperatura de la celda. La Figura 2.3.4 muestra el efecto de la temperatura de la celda sobre un módulo a un nivel de radiación solar fija. También muestra que un incremento en la temperatura disminuye el voltaje de circuito abierto e incrementa ligeramente la corriente de corto circuito.

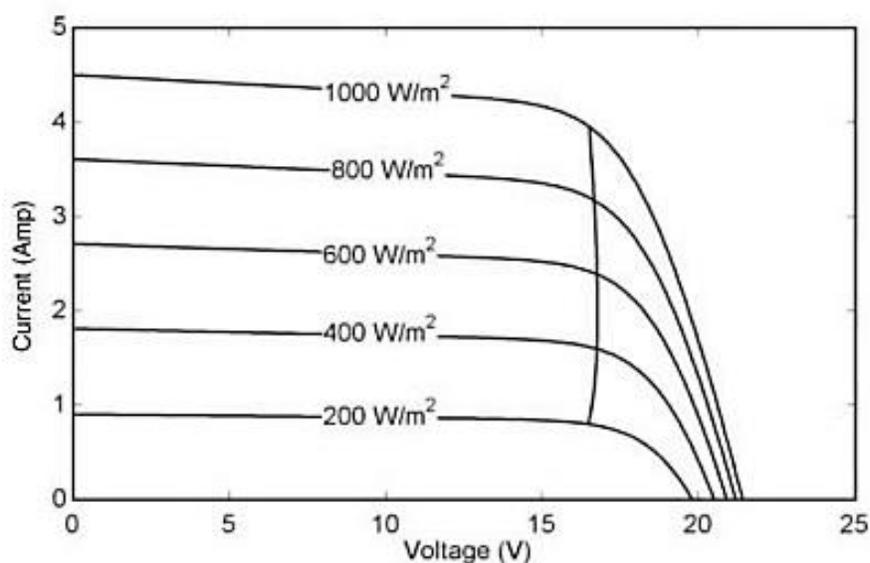


Figura 2.3.3: Curvas I-V para un módulo FV a diferentes niveles de radiación solar.

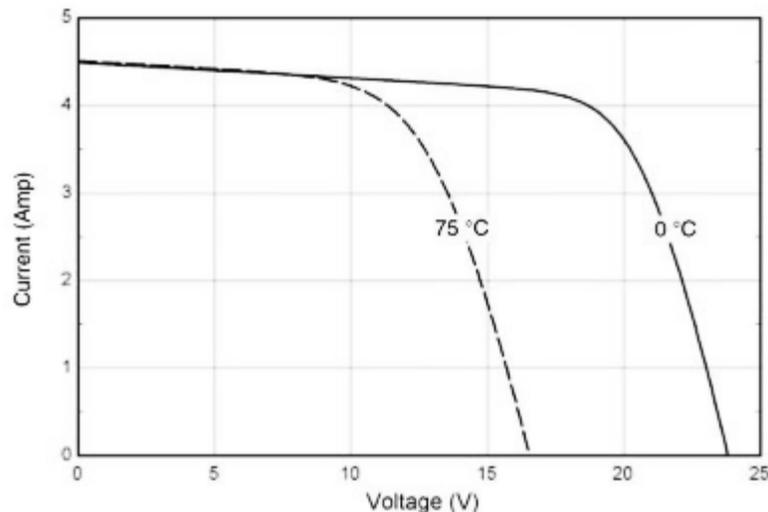


Figura 2.3.4: Curva I-V y puntos de máxima potencia de módulo FV a temperaturas de 0°C y 75°C.

Para poder calcular la potencia de salida del módulo o un arreglo FV, es necesario considerar el voltaje de operación. Cuando el arreglo FV está conectado a un bus de corriente directa (CD), normalmente el arreglo no cuenta con un controlador para el seguimiento de máxima potencia y, por tanto, el voltaje de operación viene dado por el voltaje del bus de CD al cual está conectado. Por eso es necesario encontrar en la curva I-V la corriente para ese voltaje dado, que no coincide en la mayoría de las veces con el punto de máxima potencia. De acuerdo a (Duffie et al, 2013), cuando se tiene un arreglo FV conectado a un bus de corriente alterna (CA) a través de un inversor, normalmente este cuenta con un controlador para el seguimiento del punto de máxima potencia y, por lo tanto, el inversor hace que el arreglo FV siempre opere en dicho punto. Entonces, para calcular la potencia de salida del arreglo FV, utilizando un modelo, es necesario calcular la corriente y el voltaje correspondientes al punto de máxima potencia de la curva I-V para las condiciones dadas de radiación solar y temperatura del arreglo.

A continuación, se muestra la forma en que se utiliza el modelo, para obtener la potencia de salida del módulo a partir del cálculo de la corriente I en la ecuación (3.3.1), considerando que el valor del voltaje de CD se conoce, el voltaje de operación del inversor, al cual está conectado el arreglo FV. La resistencia R_{Sh} de la mayoría de los

módulos actuales es muy grande, de manera que el ultimo término de la ecuación (3.3.1) se puede despreciar; de esta manera solo son 4 las variables desconocidas en dicha ecuación, la cual se reduce a:

$$I = I_L - I_0 \left[e^{\left(\frac{V+IR_S}{a}\right)} - 1 \right] \quad (3.3.4)$$

En condiciones de corto circuito, la corriente de diodo I_0 es muy pequeña y la corriente fotogenerada I_L es igual a la corriente de corto circuito:

$$I_L = I_{SC} \quad (3.3.5)$$

En condiciones de circuito abierto, la corriente es cero y el 1 en la ecuación (3.3.4) es insignificante comparado con el termino exponencial, así que:

$$I_0 = I_L e^{\left(\frac{-V_{OC}}{a}\right)} \quad (3.3.6)$$

En condiciones de máxima potencia, se tiene I_{Pmax} y V_{Pmax} . Sustituyendo la ecuación (3.3.6) en (3.3.4), se obtiene I_{Pmax} y V_{Pmax} :

$$I_{Pmax} = I_L - I_L e^{\left(\frac{-V_{OC}}{a}\right)} \left[e^{\left(\frac{V+IR_S}{a}\right)} - 1 \right] \quad (3.3.7)$$

En estas condiciones, se puede despreciar el 1 por que es insignificante comparado con el termino exponencial, de donde:

$$R_S = \frac{a \ln \left[1 - \frac{I_{Pmax}}{I_L} \right] - V_{Pmax} + V_{OC}}{I_{Pmax}} \quad (3.3.8)$$

Si se considera que el termino R_S es independiente de la temperatura del módulo, se puede considerar constante, y por tanto, R_S es igual a $R_{S,ref}$. En (Duffie et al, 2013), se indica que las siguientes expresiones son buenas aproximaciones para la mayoría de los módulos FV, que como se puede ver, dependen de la temperatura de la celda y la radiación solar:

$$\frac{a}{a_{ref}} = \frac{T_c}{T_{c,ref}} \quad (3.3.9)$$

$$I_L = \frac{G_T}{G_{T,ref}} [I_{L,ref} + \mu_{I,SC}(T_C - T_{C,ref})] \quad (3.3.10)$$

$$\frac{I_0}{I_{0,ref}} = \left(\frac{T_C}{T_{C,ref}} \right)^3 \exp\left(\frac{\varepsilon N_S}{a_{ref}} \left[1 - \frac{T_{C,ref}}{T_C}\right]\right) \quad (3.3.11)$$

donde T_C es la temperatura del módulo, ε es la energía de salto del material (para el silicio 1.12 eV y 1.35 eV para el arseniuro de galio). Para encontrar los valores de los parámetros de las ecuaciones (3.3.5), (3.3.6) y (3.3.8), se deben utilizar los valores de referencia. Los valores de referencia $I_{SC,ref}$, $V_{OC,ref}$, $I_{Pmax,ref}$, N_S , $\mu_{I,SC}$ y $\mu_{V,OC}$ son proporcionados por el fabricante para un módulo en particular.

En general, conociendo la radiación y la temperatura, los parámetros que definen el comportamiento energético son dados por el vector $P = [R_S R_P a I_0 \beta \alpha]$.

2.4 Redes neuronales artificiales

Las redes neuronales artificiales son sistemas inspirados en los sistemas biológicos (cerebro animal). Una red neuronal artificial (RNA) es un procesador paralelo distribuido formado por unidades simples de procesamiento (neuronas) que almacena conocimiento experimental y lo hace disponible para su uso. El conocimiento es adquirido por la red a través de un proceso de aprendizaje y las fuerzas de conexión entre las neuronas, conocidas como pesos sinápticos, son usadas para almacenar dicho conocimiento. El procedimiento usado para realizar el proceso de aprendizaje es llamado algoritmo de entrenamiento, cuya función es modificar los pesos sinápticos de la red en una manera ordenada para atender un objetivo de diseño deseado. El uso de redes neuronales ofrece las siguientes características (Sánchez, 2006):

- No linealidad: una neurona puede ser lineal o no lineal. Si una red está formada por neuronas no lineales, entonces se dice que es no lineal.
- Transformación entrada-salida: El proceso de aprendizaje de la red consiste en presentarle un ejemplo y modificar sus pesos sinápticos de acuerdo con su respuesta. Aprende, por lo tanto, una transformación entrada-salida.
- Adaptabilidad: la red tiene la posibilidad de adaptar sus pesos sinápticos a los cambios en su medio ambiente, es capaz de cambiar dinámicamente.
- Tolerancia a fallas: debido a la interconexión paralela, la falla de un procesador no impide que la red continúe presentando un buen comportamiento.

Las redes neuronales artificiales son ampliamente utilizadas en una variedad de tareas prácticas desde el monitoreo de procesos, diagnóstico de fallas, interferencia humana adaptativa, eventos naturales e inteligencia artificial tales como procesos atmosféricos y computadoras. Así también son muy importantes en aplicaciones de sistemas de control debido a su habilidad de mapeo universal y capacidad de aprendizaje. La neurona es la unidad fundamental para la operación de una red neuronal. En la Figura 2.4.1 se muestra el modelo de una neurona.

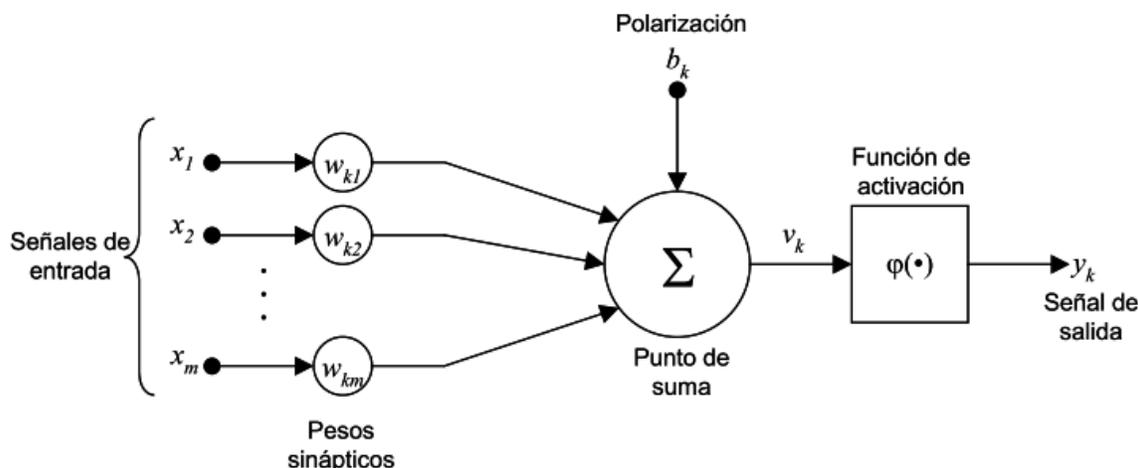


Figura 2.4.1: Modelo de una neurona artificial.

En el modelo presentado en la Figura 2.4.1 se identifican 4 elementos básicos:

- *Enlaces de conexión* (w_{kj}). Caracterizados por un peso propio. Específicamente, una señal x_j en la entrada de la sinapsis j conectada a la neurona k es multiplicada por el peso sináptico w_{kj} . Se tiene la siguiente notación: El primer subíndice se refiere a la neurona receptora y el segundo se refiere a la entrada de la sinapsis a la cual el peso se refiere. Si $w_{kj} > 0$ la conexión es excitadora; así mismo, si $w_{kj} < 0$, la conexión es inhibitoria.
- *Sumador* (Σ). Suma las señales de entrada multiplicadas por w_{kj} . Las operaciones descritas en este punto constituyen una combinación lineal.
- *Función de activación* (φ). Limita la amplitud de la salida de una neurona a un valor finito. Típicamente, el rango de amplitud normalizado de la salida de una neurona se escribe como el intervalo unitario $[0,1]$ o alternativamente $[-1,1]$.
- *Polarización* (b_k). También denominado umbral, tiene el efecto de incrementar (valor positivo) o disminuir (valor negativo) la entrada total a la función de activación.

Se puede describir una neurona k por el siguiente par de ecuaciones:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.4.1)$$

$$y_k = \varphi(u_k + b_k) \quad (2.4.2)$$

Donde x_1, x_2, \dots, x_m son las señales de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ son los pesos sinápticos de la neurona k ; u_k es la salida de la combinación lineal debida a las señales de entrada; b_k es el umbral; $\varphi(\cdot)$ es la función de activación; y y_k es la señal de salida de la neurona. El uso del umbral b_k tiene el efecto de aplicar una transformación afín a la salida de la combinación lineal en el modelo de la Figura 2.4.1, como se muestra por

$$v_k = u_k + b_k \quad (2.4.3)$$

El umbral b_k es un parámetro externo de la neurona k , pero es posible considerarlo como parte de las señales de entrada de tal forma que si se combinan las ecuaciones (2.4.1)-(2.4.3) se tiene

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (2.4.4)$$

$$y_k = \varphi(v_k) \quad (2.4.5)$$

Donde a v_k se le denomina potencial de activación. Para incorporar el umbral en (2.4.4) se considera una sinapsis x_0 cuya entrada es $x_0 = +1$ y su peso correspondiente es $w_{k0} = b_k$.

Las funciones de activación, denotadas por $\varphi(v)$, definen la salida de la neurona en función del potencial de activación. Se incluyen 4 tipos de funciones de activación básicas:

- *Función escalón o umbral.* Para este tipo de función de activación, presentada en la Figura 2.4.2, se tiene

$$\varphi(v) = \begin{cases} 1 & \text{si } v \geq 0 \\ 0 & \text{si } v \leq 0 \end{cases} \quad (2.4.6)$$

Correspondientemente, la salida de la neurona k empleando esta función de activación queda expresada como

$$y_k = \begin{cases} 1 & \text{si } v_k \geq 0 \\ 0 & \text{si } v_k \leq 0 \end{cases} \quad (2.4.7)$$

Con v_k dada por (2.4.4).

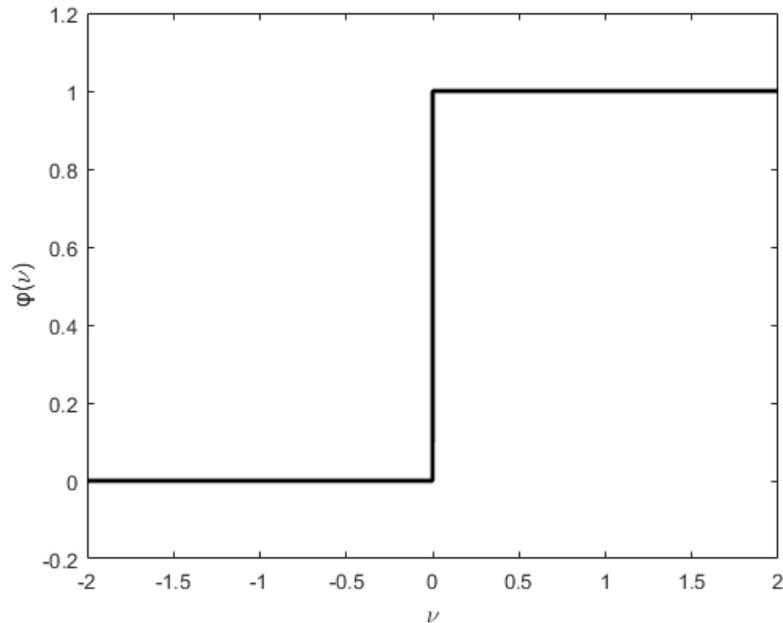


Figura 2.4.2: Función de activación escalón.

- *Función sigmoide logística.* Es la función más utilizada en la construcción de redes neuronales artificiales. Es estrictamente creciente y exhibe un balance perfecto entre el comportamiento lineal y no lineal. Esta función se define por

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (2.4.8)$$

Donde a es el parámetro que determina la pendiente de la función. Variando el parámetro a se obtienen las funciones mostradas en la Figura 2.4.3.

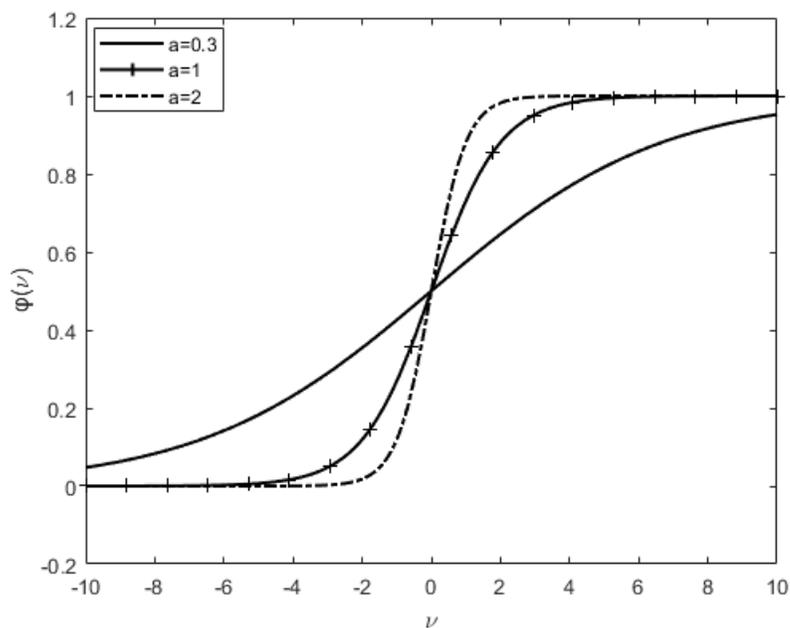


Figura 2.4.3: Función de activación sigmoide logística.

- *Función lineal a tramos.* Esta función se muestra en la Figura 2.4.4. y está definida como

$$\varphi(v) = \begin{cases} 1 & \text{si } v \geq 1 \\ v & \text{si } -1 < v < 1 \\ -1 & \text{si } v \leq -1 \end{cases} \quad (2.4.9)$$

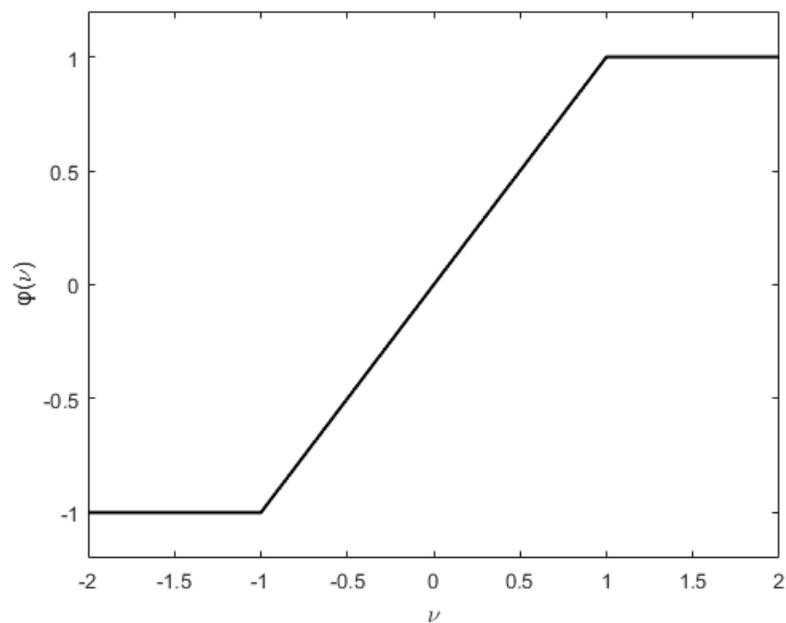


Figura 2.4.4: Función de activación lineal a tramos.

- *Función sigmoide tangente hiperbólica.* La ecuación que define esta función es

$$\varphi(v) = \frac{2}{1 + e^{-2av}} - 1 \quad (2.4.10)$$

Esta función se muestra en la Figura 2.4.5 para diferentes valores del parámetro a , el cual también tiene el efecto de variar la pendiente de la función.

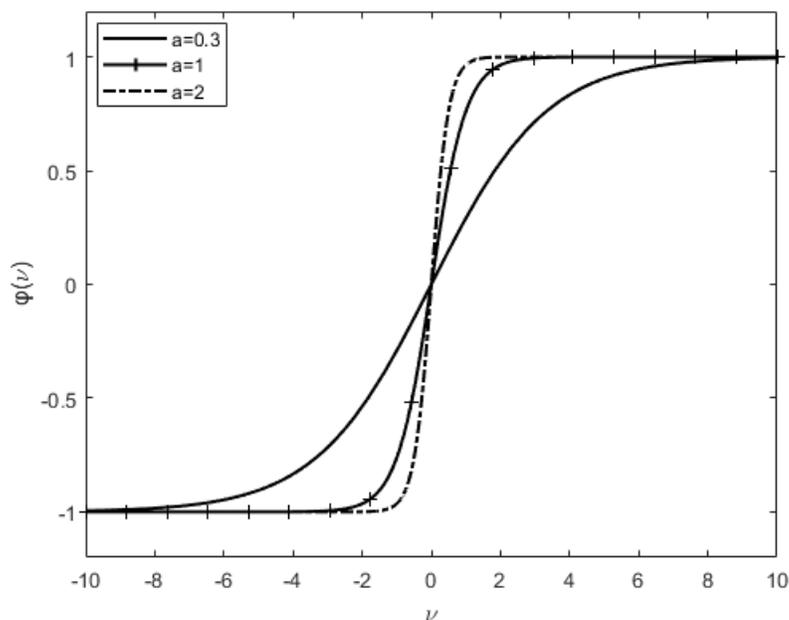


Figura 2.4.5: Función de activación sigmoide tangente hiperbólica.

Como puede observarse en las Figuras (2.4.2)-(2.4.5), las dos primeras toman valores en el intervalo cerrado $[0,1]$, mientras que las dos últimas extienden su rango de valores en el intervalo cerrado $[-1,1]$.

La no linealidad de las funciones de activación, constituye la base para que una red neuronal pueda ser el aproximador universal de funciones no lineales (Park et al 1991).

En las redes neuronales, las neuronas están organizadas por capas. En general, es posible identificar 3 clases diferentes de arquitecturas neuronales:

- *Redes neuronales unicapa.* Es la arquitectura más simple. En este caso, la capa de entrada se conecta directamente a la capa de neuronas de salida por medio de las sinapsis. Esto se muestra en la Figura 2.4.6. A esta estructura se le da la designación de unicapa porque solo tiene una capa con nodos

computacionales; para esta designación, no se toma en cuenta la capa que contiene los nodos de entrada.

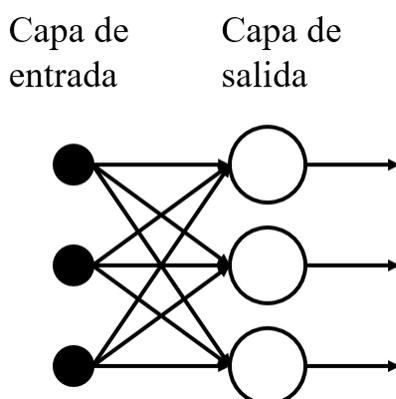


Figura 2.4.6: Red neuronal unicapa.

- *Redes neuronales multicapa.* Este tipo de arquitectura contiene una o más capas de neuronas ocultas, también llamadas unidades ocultas. La red mostrada en la Figura 2.4.7 se designa totalmente conectada, ya que todos los nodos en cada capa de la red están conectados a todos los nodos en la siguiente capa. En el caso de que falte alguna de las sinapsis de la red, entonces se dice que la red está parcialmente conectada.

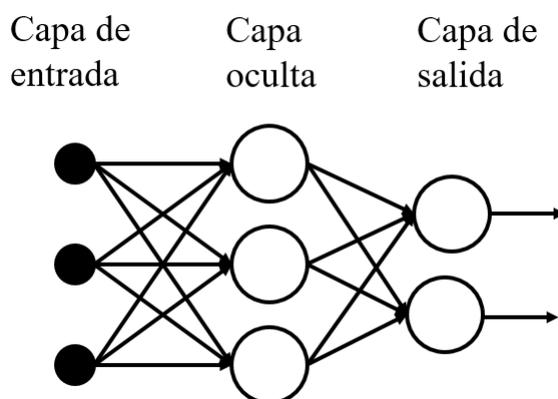


Figura 2.4.7: Red neuronal multicapa.

- *Redes neuronales recurrentes.* Este tipo de red se distingue de las arquitecturas anteriores por que tiene por lo menos un lazo de retroalimentación. Puede incluir o no capas ocultas. En la Figura 2.4.8 se muestra una red recurrente sin neuronas ocultas y en la Figura 2.4.9 se presenta este tipo de estructura con

neuronas ocultas. En las dos figuras se incluye el operador de retardo unitario z^{-1} en los lazos de retroalimentación.

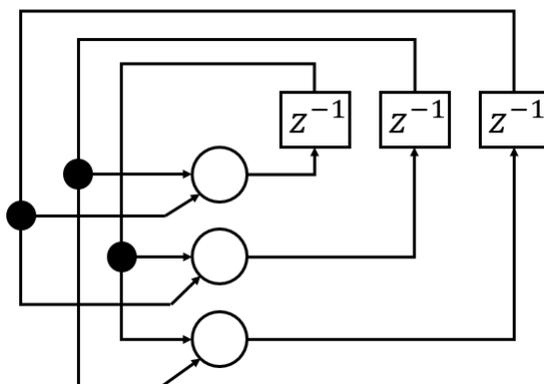


Figura 2.4.8: Red neuronal recurrente sin autolazos y sin neuronas ocultas.

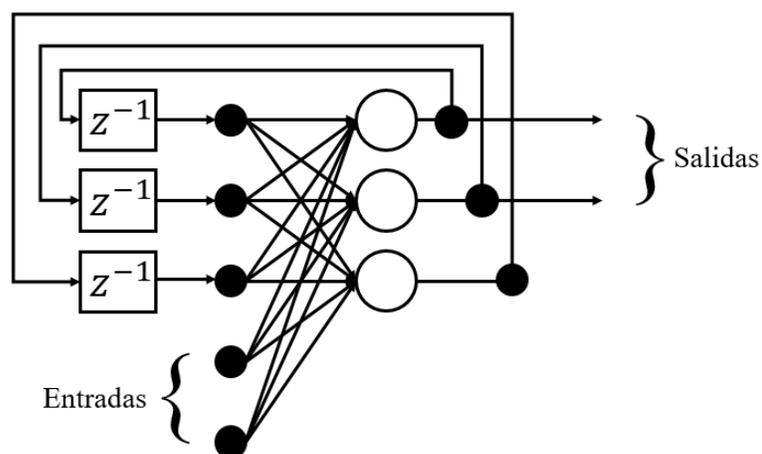


Figura 2.4.9: Red neuronal recurrente con neuronas ocultas.

Las redes neuronales pueden clasificarse también en redes unidireccionales y redes recurrentes, en función de cómo estén realizadas las conexiones entre neuronas. En las redes unidireccionales las neuronas están conectadas siguiendo el sentido de entrada hacia la salida, mientras que las redes recurrentes tienen conexiones en ambos sentidos.

Las redes unidireccionales no tienen ciclos, las neuronas están organizadas en capas que se conectan de manera unidireccional. Generalmente estas redes son denominadas estáticas, pues producen una única salida para un conjunto de entrada,

o sea, el estado de una red es independiente del estado anterior. Se muestra en la Figura 2.4.10 una estructura de red neuronal unidireccional.

Por otro lado, las redes neuronales recurrentes son sistemas dinámicos. El cálculo de una salida, en un paso, depende del paso anterior y en algunos casos del paso futuro. Las redes neuronales recurrentes son capaces de realizar una amplia variedad de tareas computacionales incluyendo el tratamiento de secuencias, la continuación de una trayectoria, la predicción no lineal y la modelación de sistemas dinámicos. Se muestra en la Figura 2.4.11 una estructura de red neuronal recurrente.

Una red neuronal recurrente se puede clasificar en parcial y/o totalmente recurrente. Las totalmente recurrentes son aquellas en que cada neurona puede estar conectada a cualquier otra y sus conexiones recurrentes son variables. Las redes parcialmente recurrentes son aquellas que sus conexiones son fijas.

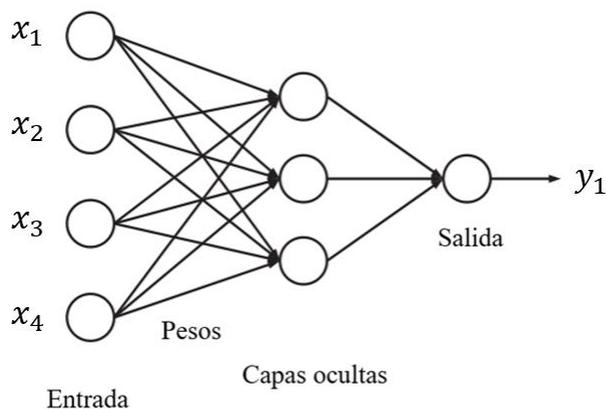


Figura 2.4.10: Red neuronal artificial unidireccional.

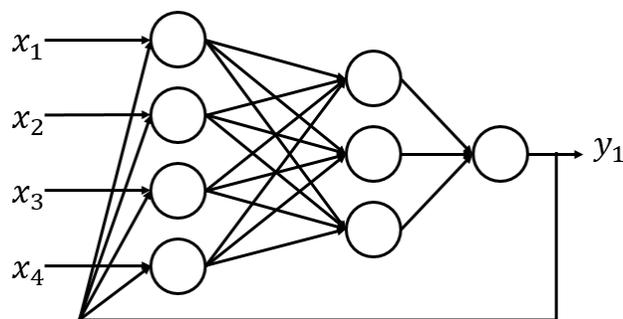


Figura 2.4.11: Red neuronal artificial recurrente.

La principal característica de las redes neuronales es su capacidad de aprendizaje, esto consiste en el ajuste de los pesos de las conexiones entre neuronas de una forma iterativa para conseguir un efecto deseado, el “aprender” las relaciones existentes entre pares de valores de entrada-salida que se le suministran, o encontrar un patrón común en datos de entrada para poder clasificar de acuerdo a los distintos patrones. Se pueden distinguir tres tipos de aprendizaje:

- *Aprendizaje supervisado*: se suministran a la red neuronal tanto el valor del vector de entradas, como el valor del vector de salidas (valor del vector de salidas esperado correspondiente a cada valor del vector de entradas). Durante el proceso de aprendizaje, la red neuronal ajusta sucesivamente el peso de las conexiones de forma que se minimiza el error entre los valores del vector de salidas de la red neuronal y los valores del vector de salidas esperado. Este tipo de aprendizaje es usual en aproximación de funciones no lineales con redes neuronales.
- *Aprendizaje no supervisado*: la red neuronal no recibe ningún valor esperado del vector de salidas (de ahí lo de aprendizaje no supervisado), pero busca en los valores del vector de entradas alguna propiedad o correlación que los permita clasificar de acuerdo a la misma.
- *Aprendizaje reforzado*: es un caso especial de aprendizaje supervisado en el que el valor del vector de salidas esperado no es suministrado, sino que únicamente se suministra a la red neuronal la información precisa de si el valor del vector de salidas es igual o no al esperado, en una especie de retroalimentación de ajuste.

Las neuronas están conectadas en diferentes capas con valores de pesos sinápticos. El algoritmo de aprendizaje intenta mapear la relación de entrada y salida actualizando los valores de pesos sinápticos. La salida generada por la red se compara con la salida deseada y luego se calcula el error. Por lo tanto, los valores de pesos y sesgos de la red se actualizan en base al error. La función de activación se aplica a la entrada ponderada para la salida de la red. Este ciclo continuará hasta que se logre la salida deseada.

El perceptrón multicapa

Un perceptrón multicapa (MLP) es un modelo neuronal artificial unidireccional que asigna conjuntos de datos de entrada en un conjunto de salidas apropiadas. Un MLP consta de múltiples capas de nodos de un grafo dirigido, con cada capa totalmente conectada a la siguiente. Excepto para los nodos de entrada, cada nodo es una neurona (o elemento de procesamiento) con una función de activación lineal. MLP utiliza una técnica de aprendizaje supervisado denominado retropropagación para la formación de la red (Rosenblatt. 1961; Rumelhart, et al, 1986;). MLP es una modificación del perceptrón lineal estándar y pueden distinguir los datos que no son linealmente separables. (Cybenko 1989) Este es uno de los tipos de redes más comunes. Se basa en otra red más simple llamada perceptrón simple solo que el número de capas ocultas puede ser mayor o igual que una. Es una red unidireccional. La arquitectura típica de esta red es la siguiente (Figura 2.4.12):

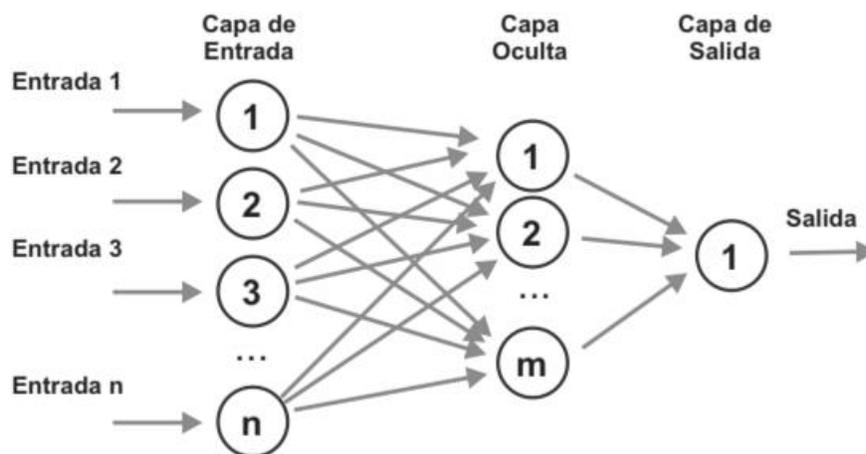


Figura 2.4.12: Red neuronal perceptrón multicapa.

Redes neuronales recurrentes de alto orden

Las redes neuronales recurrentes son aquellas que tienen uno o más lazos de retroalimentación. La retroalimentación puede ser local, es decir, la neurona se retroalimenta a sí misma, o global, cuando la neurona retroalimenta neuronas de la misma capa o de capas anteriores. Una red recurrente responde temporalmente a una señal de entrada externa. Más aun, la retroalimentación habilita a las redes neuronales recurrentes a tener una representación en espacio de estado, lo cual las hace convenientes para diversas aplicaciones.

La palabra orden se utiliza para referirse a la forma en que se define el potencial de activación de una neurona. Cuando el potencial de activación local se combina con multiplicaciones de las señales provenientes de la retroalimentación o cuando se multiplican estas últimas junto con las señales de entrada externas a la red, se produce una red neuronal de orden r , donde r representa el número de señales multiplicadas. La frase alto orden se emplea cuando la entrada a una neurona incluye el producto de más de dos señales. En la Figura 2.4.13 se presenta una red neuronal de segundo orden.

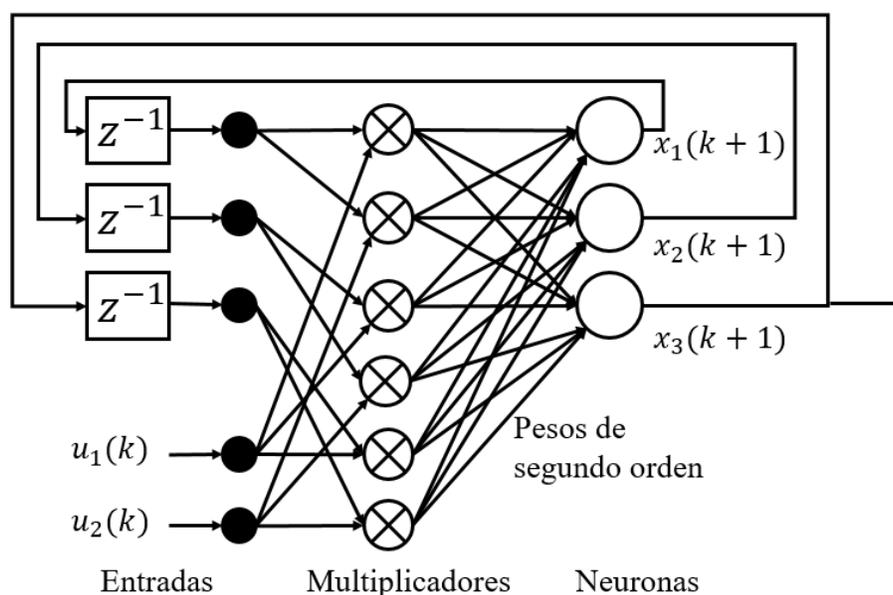


Figura 2.4.13: Red neuronal de segundo orden.

2.5 Entrenamiento por el Filtro Extendido de Kalman

El filtro de Kalman es un estimador utilizado para estimar el estado de un sistema dinámico lineal perturbado por el ruido blanco gaussiano usando mediciones que son funciones lineales del estado del sistema, pero corrompidas por ruido blanco gaussiano aditivo (Castañeda, 2013). El modelo matemático utilizado en la derivación del filtro de Kalman es una representación razonable para muchos problemas de interés práctico, incluyendo problemas de control, así como problemas de estimación. El modelo de filtro de Kalman también se utiliza para el análisis de problemas de medición y estimación.

Los principales usos de la filtración de Kalman han sido en sistemas de control modernos, en el rastreo y navegación de todo tipo de vehículos y en el diseño predictivo de sistemas de estimación y control. Estas actividades técnicas fueron posibles gracias a la introducción del filtro de Kalman. El filtrado extendido de Kalman se usó en la primera aplicación del filtro de Kalman: el problema de navegación espacial para las misiones de Apolo a la luna y retorno. El enfoque se ha aplicado con éxito a muchos problemas no lineales desde entonces.

El éxito depende de que el problema sea casi lineal, en el sentido de que los errores no modelados debidos a la aproximación lineal son insignificantes comparados con los errores modelados en comparación con los errores modelados debido a la incertidumbre dinámica y el ruido del sensor.

Para el entrenamiento de la red neuronal se hace uso del filtro extendido de Kalman. A los dos conjuntos de pesos, localizados entre la primera y segunda capa oculta y entre la capa oculta y la capa de salida, se construyó un vector de pesos que será determinado mediante el Filtro de Kalman. El Filtro de Kalman (KF) estima el estado de un sistema lineal con ruido blanco aditivo en el estado y la salida. Antes de aplicar el Filtro de Kalman es necesario considerar las ecuaciones que sirven como base para derivar el Filtro Extendido de Kalman (EKF), aplicado a sistemas no lineales (Deossa, 2009).

Considere un sistema dinámico no lineal descrito por el siguiente modelo en espacio de estado

$$w(k + 1) = F_{k+1,k} w(k) + v_1(k) \quad (2.5.1)$$

$$y(k) = H(k)w(k) + v_2(k) \quad (2.5.2)$$

La Ecuación (2.5.1) es conocida como la ecuación del proceso; $F_{k+1,k}$ denota la función matricial no lineal de transición $w(k)$ de la iteración k a la iteración $k + 1$ y $v_1(k)$ es el ruido en el proceso. Por otra parte, la Ecuación (2.5.2) es conocida como la ecuación de observación o medición, la cual representa la variable medida $y(k)$ en la iteración k , $H(k)$ es la matriz de medición y $v_2(k)$ es el ruido en la medición. El ruido en la medición $v_2(k)$ es ruido independiente, blanco, gaussiano, con media cero y con matriz de covarianza $E[v^2(l)v^2T(l)] = \delta_{k,l}R(k)$. Similarmente, el ruido del proceso $v_1(k)$ está también caracterizado como ruido independiente, blanco, gaussiano y con matriz de covarianza $E[v^1(l)v^1T(l)] = \delta_{k,l}Q(k)$. Debido a que el mapeo de la red neuronal es no lineal, se requiere un tipo de entrenamiento por el EKF. Resulta el siguiente conjunto de ecuaciones mediante las cuales se actualizan los pesos sinápticos de las redes neuronales en cada iteración.

$$K(k) = P(k)H^T(k)[R + H(k)P(k)H^T(k)] \quad (2.5.3)$$

$$w(k + 1) = w(k) + K(k)[y(k) - \hat{y}(k)] \quad (2.5.4)$$

$$P(k + 1) = P(k) - K(k)H(k)P(k) + Q \quad (2.5.5)$$

donde $P(k)$ y $P(k + 1)$ son las matrices de covarianza del error de la predicción en los iteraciones k y $k + 1$, respectivamente; $w(k)$ es el vector de pesos (estados); NW representa el número total de pesos sinápticos en la red neuronal; $y(k)$ es el vector con la salida deseada de la red; $\hat{y}(k)$ es la salida de la red; n es el número total de salidas de la red neuronal, $K(k)$ es la matriz de ganancia de Kalman; Q es la matriz de covarianza del ruido del proceso; R es la matriz de covarianza del ruido de medición; $H(k)$ es la matriz que contiene las derivadas de cada salida de la red neuronal, (y_i) , con respecto a cada uno de los pesos, (w_j) de la red, como se indica por:

$$H_{ij}(k) = \left[\frac{\partial \hat{y}(k)}{\partial w(k)} \right]_{w(k) - \hat{w}(k+1)} \quad (2.5.6)$$

$$i = 1, \dots, o; j = 1, \dots, NW$$

Las matrices P , Q y R son inicializadas como matrices diagonales con entradas P_0 , Q_0 y R_0 , respectivamente.

Para la aplicación del filtro como método de entrenamiento, los estados del filtro pasan a ser los pesos sinápticos de la red. Y la salida de la red neuronal es la medición que usa el filtro. El algoritmo construido opera bajo el siguiente esquema mostrado en la Figura 2.5.1.

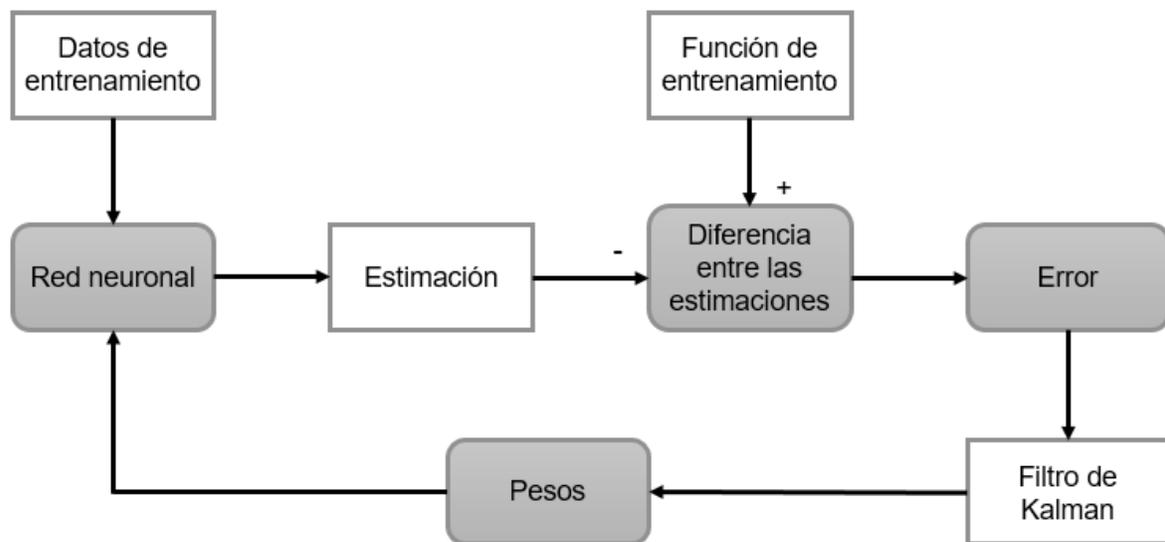


Figura 2.5.1: Esquema de funcionamiento del filtro de Kalman como entrenamiento a la red neuronal.

3. METODOLOGÍA

3.1 Muestreo de datos

Se obtuvieron datos de potencia producida por el arreglo de paneles fotovoltaicos y mediciones de variables meteorológicas. Las mediciones de potencia del arreglo de paneles fotovoltaicos provienen de una instalación doméstica ubicada en la ciudad de Mérida en Yucatán. Para esta instalación se han empleado módulos fotovoltaicos marca Solartec® modelo S60PC de 250 watts. El arreglo fotovoltaico se muestra en la Figura 3.1.1



Figura 3.1.1: Arreglo de módulos solares fotovoltaicos.

Los datos ambientales son proporcionados por la estación climatológica mostrada en la Figura 3.1.2, perteneciente al centro meteorológico de la facultad de ingeniería de la UADY. Las mediciones fueron realizadas con un equipo Davis Vantage Pro2, el cual cuenta con sensores de lluvia, viento, temperatura y humedad para mediciones principales y otras mediciones derivadas. Existe una diferente localización entre la fuente de medición y el arreglo fotovoltaico, lo cual no es común, pero se tienen limitaciones técnicas. En general las variables son similares, a excepción de la

velocidad de viento, pero dado que el índice de correlación de esta variable con la potencia es bajo, se puede usar de manera indirecta.



Figura 3.1.2: Estación meteorológica.

Después de la captura y procesamiento de los archivos de datos, se han obtenido la serie de tiempo de la producción de potencia y la serie de tiempo de datos meteorológicos. Los datos de potencia y meteorológicos constan de mediciones cada cinco minutos desde el 01 marzo de 2016 al 15 de agosto de 2016. El vector de datos meteorológicos consta de 38 filas de parámetros de los cuales para el entrenamiento de la red se eligen temperatura, humedad, velocidad del viento, presión atmosférica, radiación solar.

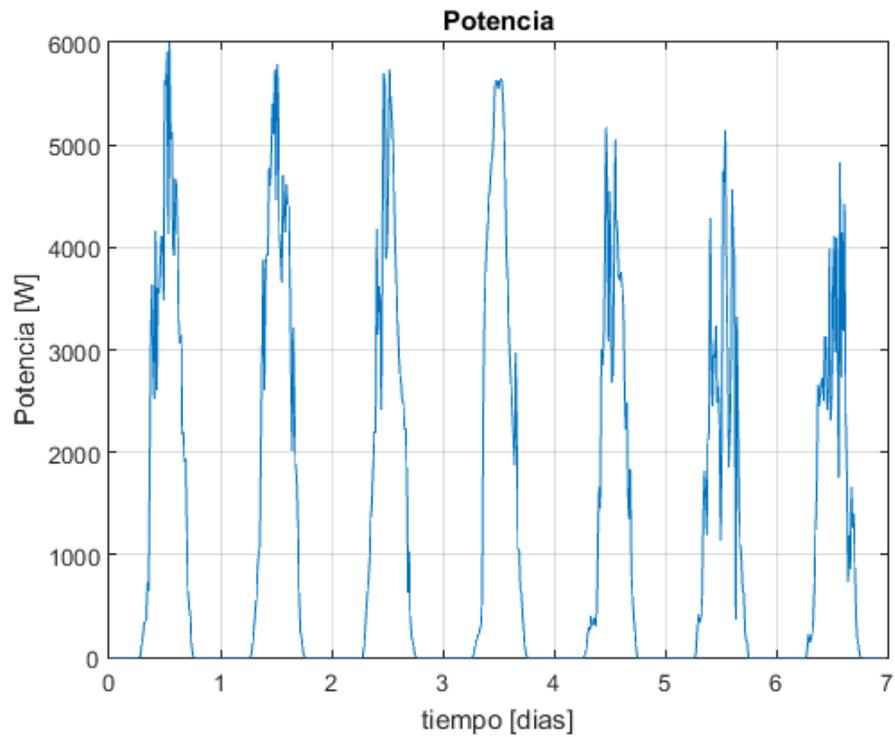


Figura 3.1.3: Mediciones de potencia.

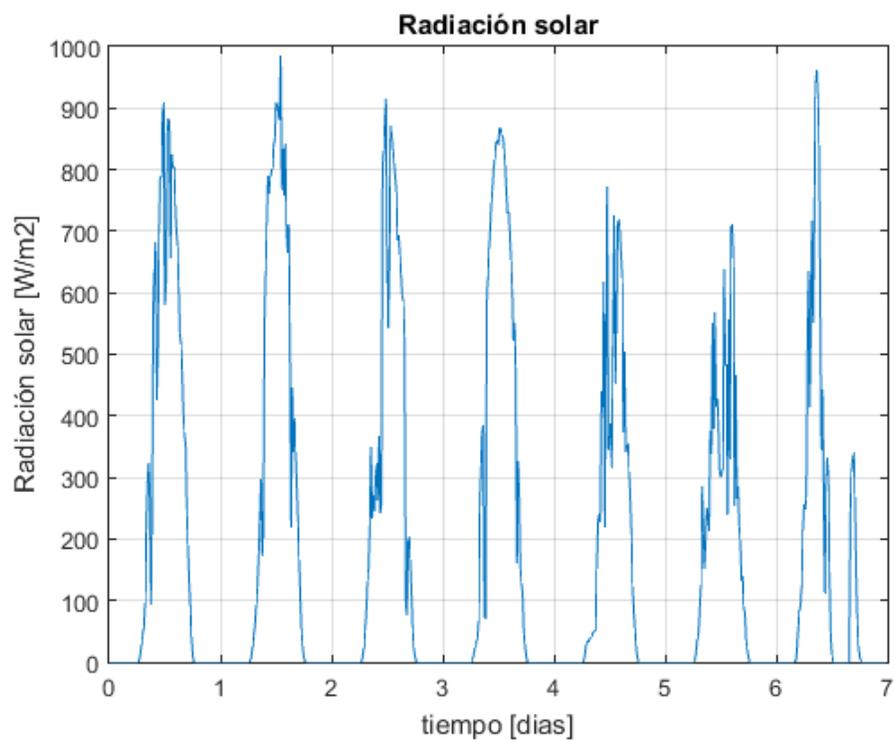


Figura 3.1.4: Mediciones de radiación solar.

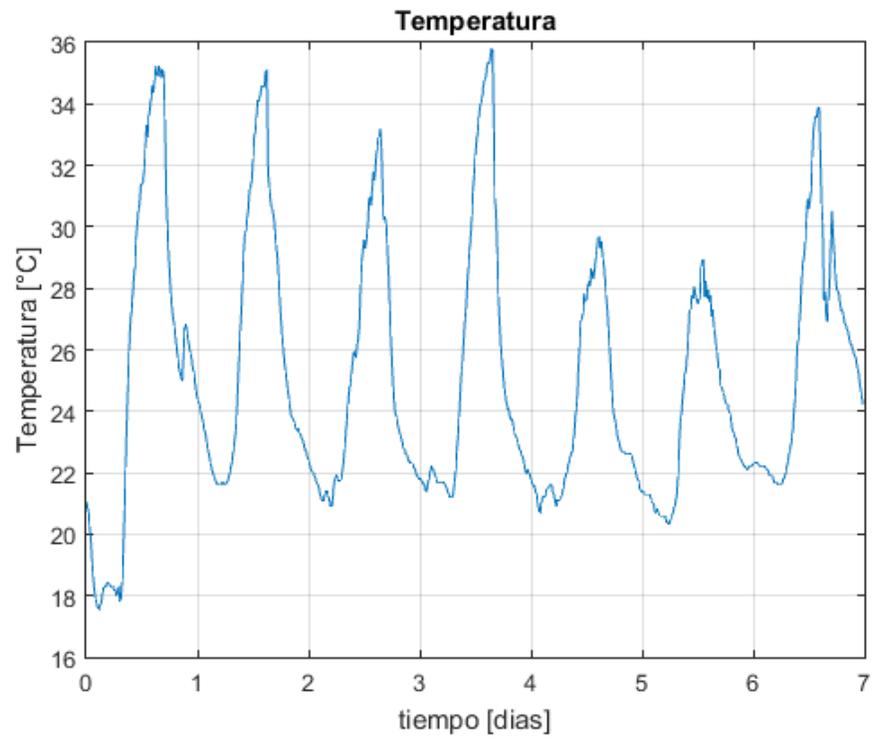


Figura 3.1.5: Mediciones de temperatura.

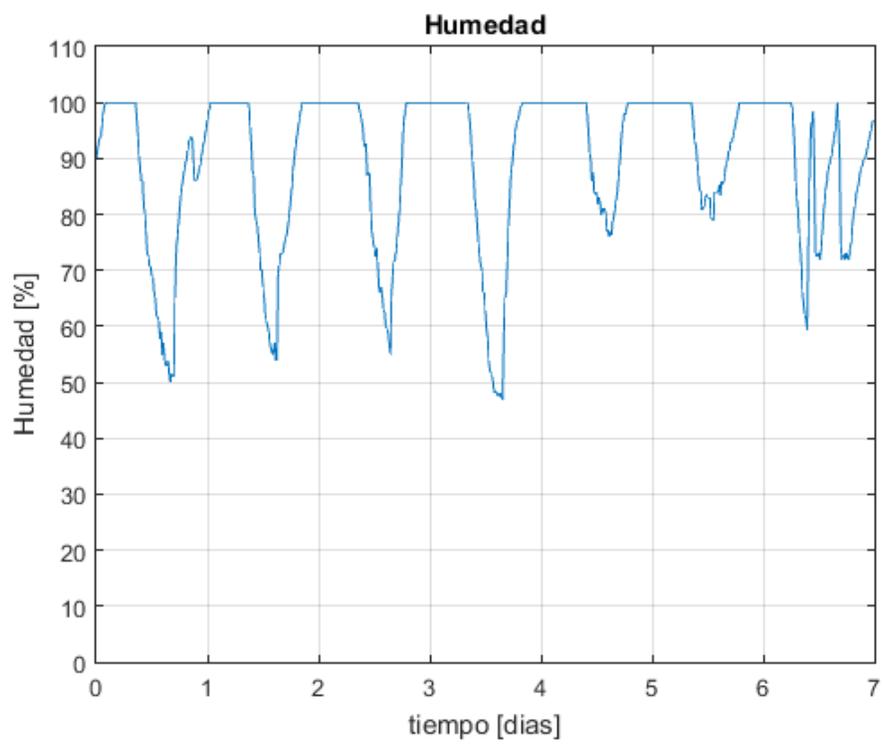


Figura 3.1.6: Mediciones de humedad.

Mediante métodos descriptivos se analizaron tablas y gráficos, mostrados en las Figura 3.1.3 a Figura 3.1.6 para los datos de las series de tiempo. Se seleccionó un intervalo de 7 días, ya que es un periodo de tiempo manejable y entendible de manera visual. Comparando dos series de tiempo, también se calcularon y graficaron las correlaciones cruzadas entre las series. Con el objetivo de conocer cuales datos deben de alimentar el modelo, se analizó la correlación que existe entre la potencia producida (variable dependiente) y las variables independientes de radiación solar, velocidad de viento, humedad y temperatura.

Tabla 3.1.1: Correlación entre las mediciones

	Potencia del arreglo	Temperatura exterior	Humedad relativa	Velocidad de viento	Radiación Solar
Potencia del arreglo		0.6926	-0.6516	0.2852	0.9311
		(48384)	(48384)	(48384)	(48384)
		0.0000	0.0000	0.0000	0.0000
Temperatura exterior	0.6926		-0.8417	0.4052	0.7388
	(48384)		(48384)	(48384)	(48384)
	0.0000		0.0000	0.0000	0.0000
Humedad relativa	-0.6516	-0.8417		-0.4655	-0.6903
	(48384)	(48384)		(48384)	(48384)
	0.0000	0.0000		0.0000	0.0000
Velocidad de viento	0.2852	0.4052	-0.4655		0.3132
	(48384)	(48384)	(48384)		(48384)
	0.0000	0.0000	0.0000		0.0000
Radiación Solar	0.9311	0.7388	-0.6903	0.3132	
	(48384)	(48384)	(48384)	(48384)	
	0.0000	0.0000	0.0000	0.0000	

En la Tabla 3.1.1 se muestran las correlaciones momento producto de Pearson entre cada par de variables. Estos coeficientes de correlación oscilan entre -1 y +1 y miden la fuerza de la relación lineal entre las variables. También se muestra, entre paréntesis, el número de pares de valores de datos utilizado para calcular cada coeficiente.

El tercer número en cada ubicación de la tabla es un valor-P que prueba la significancia estadística de las correlaciones estimadas. Un valor-P inferior a 0.05 indica una correlación diferente de cero estadísticamente significativa a un nivel de confianza del 95,0%. Los siguientes pares de variables tienen valores-P por debajo de 0.05:

Potencia y humedad	Temperatura y velocidad de viento
Potencia y temperatura	Temperatura y radiación solar
Potencia y velocidad de viento	Humedad y velocidad de viento
Potencia y radiación solar	Humedad y radiación solar
Temperatura y humedad	Velocidad de viento y radiación solar

Tabla 3.1.2: Coeficientes de correlación de variables a emplear.

Variable	Coefficiente de Correlación
Radiación solar	0.9311
Temperatura	0.6926
Velocidad del viento	0.2852
Humedad	-0.6516

El análisis de correlación llevó a seleccionar los valores de entrada que sean significativos. Para fines de esta investigación se tomarán las variables de Radiación solar, velocidad del viento, humedad y temperatura los cuales se muestran en la Tabla 3.1.2.

Para cuantificar la relación entre dos series del tiempo o del clima, o entre una de ellas y otra variable de naturaleza no climática, se recurre a métodos paramétricos como el coeficiente de correlación lineal, como el de Pearson o a no paramétricos como el de Spearman o el de Mann-Kendall.

En varias situaciones no se aprecia la correlación entre los eventos expresados por estos coeficientes, puesto que ellos solo expresan la asociación en tiempo simultáneo, en cambio cuando se les aplica a las series la técnica estadística de la correlación cruzada, es viable que resalten claras asociaciones entre las series.

Es decir, la correlación cruzada es la correlación entre una serie X_t en un tiempo dado, t , con otra serie en un tiempo posterior Y_{t+k} . La correlación cruzada en el retardo k mide la fuerza de la relación lineal entre el valor de X_t en el tiempo t y el valor de Y_t k períodos anteriores. Se puede utilizar para determinar si X_t ayudaría al pronóstico Y_t .

En la Figura 3.1.7 se muestra la correlación cruzada entre la variable potencia y la radiación solar. Para este caso, 34 de los 49 coeficientes de correlación cruzada son estadísticamente significativos al nivel de confianza de un 95,0%.

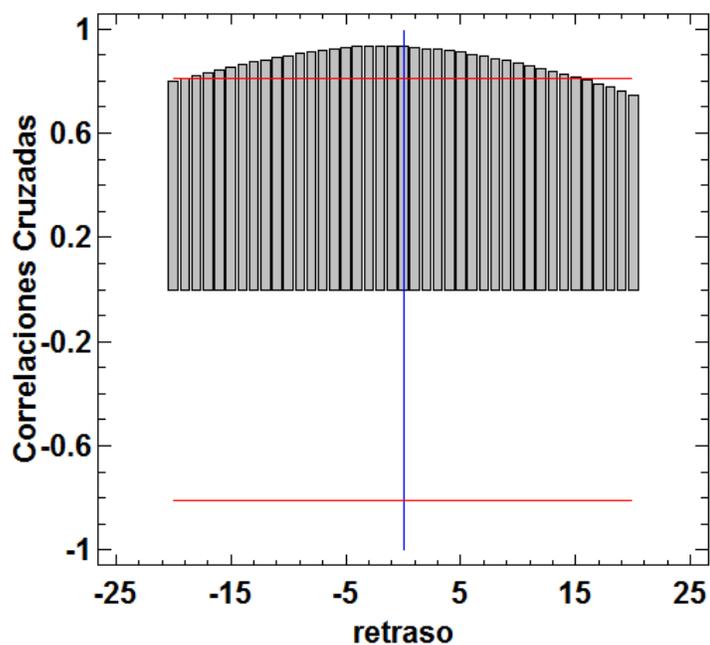


Figura 3.1.7: Correlaciones cruzadas para potencia con radiación solar.

En la Figura 3.1.8 se muestra la correlación cruzada entre la variable potencia y la temperatura. En este caso, 21 de los 49 coeficientes de correlación cruzada son estadísticamente significativos al nivel de confianza de un 95,0%. Destacan los coeficientes a partir de -6.

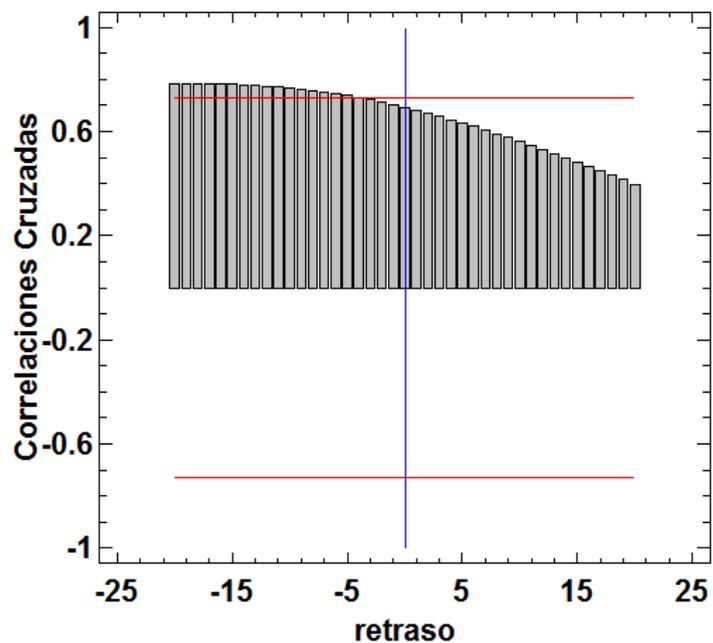


Figura 3.1.8: Correlaciones cruzadas para potencia con temperatura.

En la Figura 3.1.9 se muestra la correlación cruzada entre la variable potencia y la velocidad del viento. En este caso, ninguno de los 49 coeficientes de correlación cruzada es estadísticamente significativo al nivel de confianza del 95,0%. En este caso ninguno de los coeficientes sobresale.

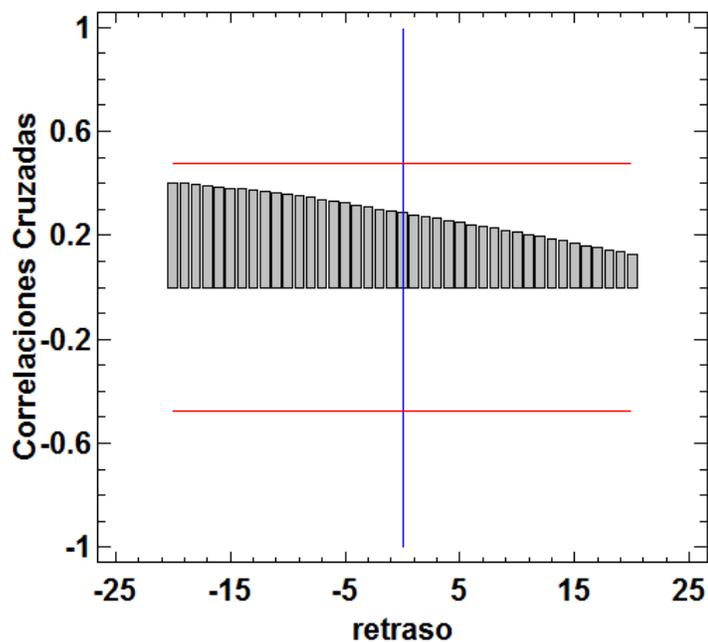


Figura 3.1.9: Correlaciones cruzadas para potencia con velocidad de viento.

Esta Figura 3.1.10 se muestra la correlación cruzada entre la variable potencia y la humedad. En este caso, 18 de los 49 coeficientes de correlación cruzada son estadísticamente significativas al nivel de confianza del 95,0%. Se destacan los coeficientes a partir de -5.

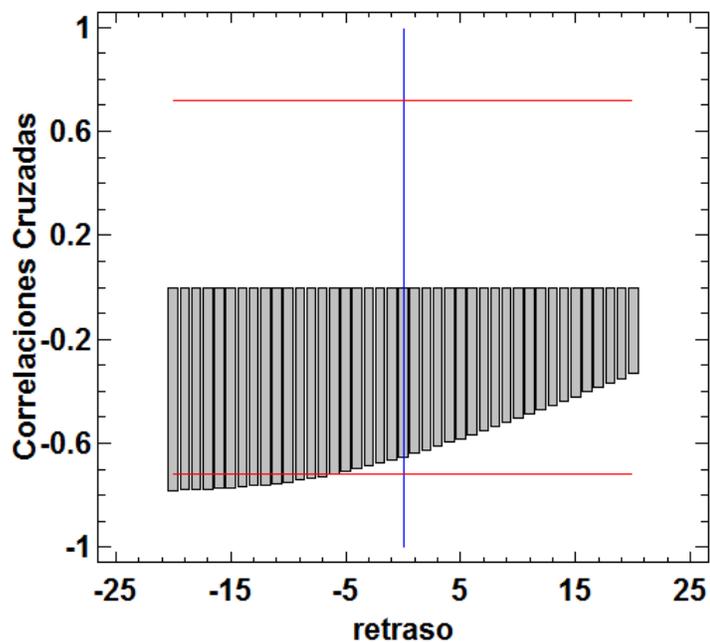


Figura 3.1.10: Correlaciones cruzadas para potencia con humedad.

Del análisis de correlación cruzada se obtienen los retrasos significativos de las variables de entrada, esto se muestra en la Tabla 3.1.3.

Tabla 3.1.3: Retrasos de tiempo significativos.

Variable	Inicio de retrasos significativo
Radiación solar	-1
Temperatura	-6
Humedad	-5
Velocidad de viento	Ninguno

3.2 Cálculo de la dimensión de la serie de tiempo

Para el cálculo de la dimensión del sistema, se empleó el estudio de las series de tiempo mediante la teoría de embebimiento, esta propone un cambio de paradigma al estudio de las series de tiempo, tanto desde el campo de la estadística y la inteligencia artificial. Las técnicas usadas suponen que los conjuntos de datos observados en una serie de tiempo tienen su origen en un sistema dinámico determinista con una dimensión desconocida. Si se supone que el sistema puede ser descrito por medio de un conjunto reducido de variables, debe aprovecharse la información disponible de la mejor forma posible.

Ha habido mucha investigación en torno a cómo determinar la dimensión óptima de una serie de tiempo escalar en base al Teorema de Takens (Cao, 1997). Los métodos básicos, que por lo general se utilizan para elegir la dimensión mínima de la serie de tiempo, son los siguientes: el cálculo de invariantes en el atractor, la descomposición de valor singular y el método de falsos vecinos. Un método práctico para seleccionar el espacio es el propuesto por Cao (1997) para determinar la dimensión mínima; que supera la mayoría de las deficiencias de las metodologías mencionadas anteriormente, como la alta dependencia de los parámetros de diseño y el alto coste computacional, entre otros.

Consideremos una serie de tiempo x_1, x_2, \dots, x_n y definamos un conjunto de vectores de retardo en el tiempo

$$y_i = [X_i, X_{i+\tau}, \dots, X_{i+(d-1)\tau}] \quad (3.2.1)$$

$$i = 1, 2, \dots, N - (d - 1)\tau$$

donde d es la dimensión embebida y τ es el tiempo de retardo. Esta dimensión se determina a partir de la evolución de la función $E(d)$ definida como

$$E(d) = \frac{1}{N - d\tau} \sum_{i=1}^{N-d\tau} \frac{\|y_i(d+1) - y_{n(i,d)}(d+1)\|}{\|y_i(d) - y_{n(i,d)}(d)\|} \quad (3.2.2)$$

$$i = 1, 2, \dots, N - d\tau$$

donde $n(i, d)$ es un entero tal que $y_{n(i,d)}(d)$ es el vecino más cercano de $y_i(d)$ (Kennel, et al 1992). $E(d)$ es dependiente únicamente de la dimensión d y el retraso τ . Para investigar la variación desde d a $d + 1$, es necesario definir

$$E_1(d) = E(d + 1)/E(d) \quad (3.2.3)$$

$E_1(d)$ deja de cambiar cuando d es mayor que algún valor d_0 si la serie de tiempo proviene de un atractor (conjunto de valores numéricos hacia los cuales tiende un sistema a evolucionar). Entonces $d_0 + 1$ es la mínima dimensión embebida que se busca. En la Figura 3.2.1 se muestra la potencia para un día típico y la evolución de los coeficientes de Cao, donde puede concluirse que en los valores mayores que $d_0 = 6$ el valor de $E_1(d)$ permanece cerca de 1.

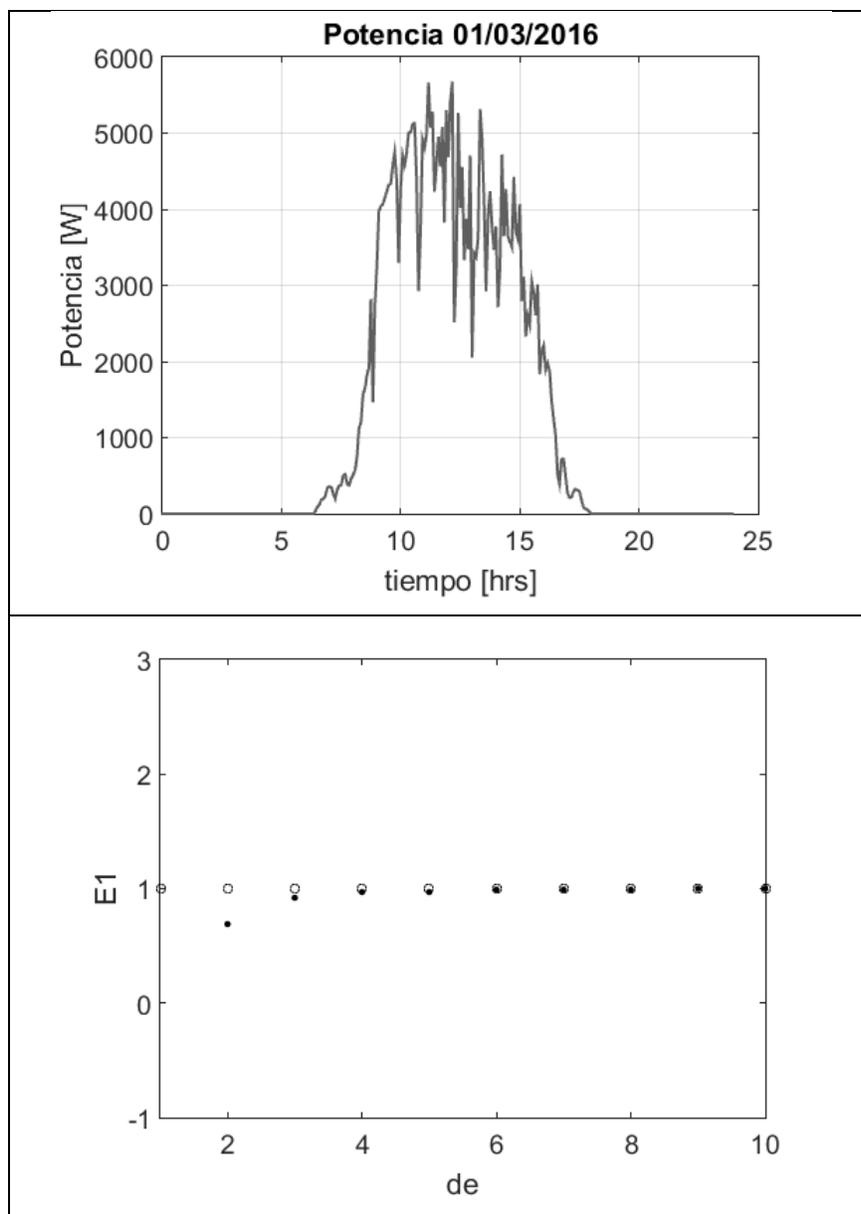


Figura 3.2.1: Resultado de aplicar el método de Cao a la serie de tiempo de potencia.

Los resultados presentados en este capítulo servirán como base para construir el vector de series de tiempo utilizado para entrenar los modelos de predicción mediante redes neuronales artificiales. Las variables importantes se obtienen de un análisis de correlación con la variable de potencia. Empleando el método de Cao se halló la dimensión mínima de embebimiento para la variable a pronosticar.

4. RESULTADOS

Para obtener el diseño del modelo de predicción más adecuado, se procede a emplear varios tipos de redes neuronales, como punto de partida se tiene el perceptrón multicapa, seguido a esto se tiene emplean las redes neuronales de alto orden recurrentes entrenadas mediante el filtro de Kalman.

El flujo de trabajo para el proceso general de diseño de red neural tiene siete pasos principales:

- 1 Recolectar datos.
- 2 Diseñar la red.
- 3 Configurar la red.
- 4 Inicializar los pesos y sesgos.
- 5 Capacitar la red.
- 6 Validar la red (análisis post-entrenamiento).
- 7 Implementar la red.

Se realizaron entrenamientos, validaciones y pruebas mediante el software MATLAB. En este trabajo, la radiación solar (R), temperatura (T), humedad (H) y velocidad de viento (V) son las entradas y la potencia del arreglo fotovoltaico (P) es la salida.

Para la mejora de los resultados, esto es, si la red no es suficientemente precisa, puede intentarse inicializar la red y el entrenamiento de nuevo. Cada vez que inicializa una red de estática los parámetros de red son diferentes y pueden producir diferentes soluciones.

Como un segundo enfoque, se puede aumentar el número de neuronas ocultas por encima de 20. El número de neuronas en la capa oculta da a la red más flexibilidad porque la red tiene más parámetros que puede optimizar. (Aumentar gradualmente el tamaño de la capa: si hace que la capa oculta sea demasiado grande, podría causar que el problema se sub-caracterice y la red debe optimizar más parámetros que los

vectores de datos para restringir estos parámetros). Una tercera opción es probar una función de entrenamiento diferente. Por último, se intenta utilizar datos de entrenamiento adicionales. Proporcionar datos adicionales para la red es más probable que produzca una red que generaliza bien a los nuevos datos.

Las redes multicapa son capaces de realizar casi cualquier cálculo lineal o no lineal, y pueden aproximar arbitrariamente cualquier función razonable. Sin embargo, aunque la red que se está formando es capaz (teóricamente) de realizar correctamente la aproximación, el aprendizaje por retropropagación y sus variaciones pueden no encontrar siempre una solución.

El desempeño de estos modelos ha sido evaluado en base al error cuadrático medio (MSE). Si \hat{Y} es un vector de n predicciones y Y es el vector de los verdaderos valores, entonces el (estimado) MSE del predictor está dado por la siguiente Ecuación 4.1.1.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (4.1.1)$$

Esta es una cantidad conocida, calculado dada una muestra particular (y por lo tanto es dependiente de la muestra).

Dado que el MSE es la métrica más utilizada para presentar los resultados en los estudios observados, con el fin de permitir algunas comparaciones entre modelos, hemos tratado de describir resultados con respecto a esta métrica.

4.1 Perceptrón multicapa

Para encontrar el mejor resultado para el perceptrón multicapa, se procede a probar diferentes arquitecturas, configuraciones y pruebas. Se tienen los siguientes casos mostrados en la Tabla 4.1.1:

Tabla 4.1.1: Casos para perceptrón multicapa.

Caso	Tipo de variación
1	Número de neuronas en la capa oculta
2	Porcentaje de división de datos para entrenamiento, validación y pruebas
3	Número de días como cantidad de datos de entrada
4	Número de retardos en las entradas
5	En el horizonte de predicción
6	Cantidad de retardos de la entrada de radiación solar

La arquitectura de red se muestra a continuación en la Figura 4.1.1, la cual se fue variando como se explicó en los casos antes mostrados. Se empleó el algoritmo de entrenamiento Levenberg-Marquardt.

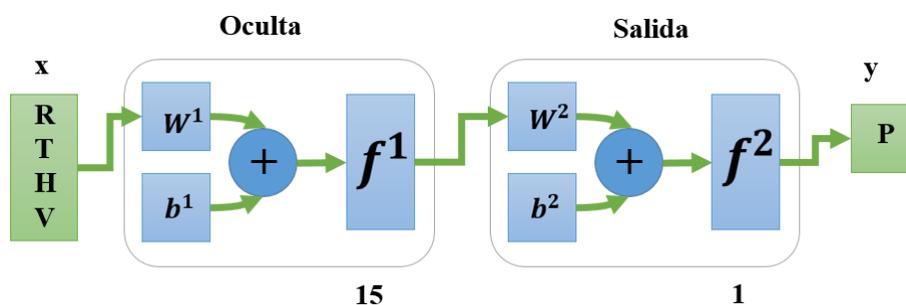


Figura 4.1.1: Estructura de red neuronal perceptrón multicapa.

Caso 1: Variación de número de neuronas en la capa oculta.

En la Figura 4.1.2 se muestra el resultado del caso 1.1 el cual emplea 5 neuronas en la capa oculta. Para este caso el error cuadrático medio alcanza un valor de 6.12×10^{-3} . En la Figura 4.1.3 se muestra el resultado del caso 1.3, con 15 neuronas en la capa oculta. Para este caso el error cuadrático medio alcanza un valor de 4.08×10^{-3} .

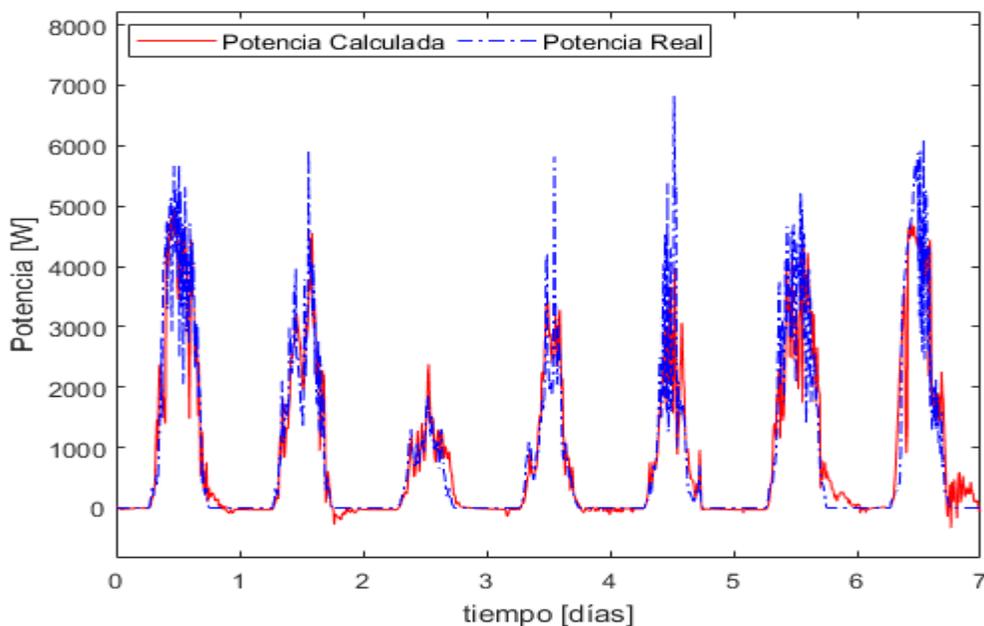


Figura 4.1.2: Resultados perceptrón multicapa caso 1.1.

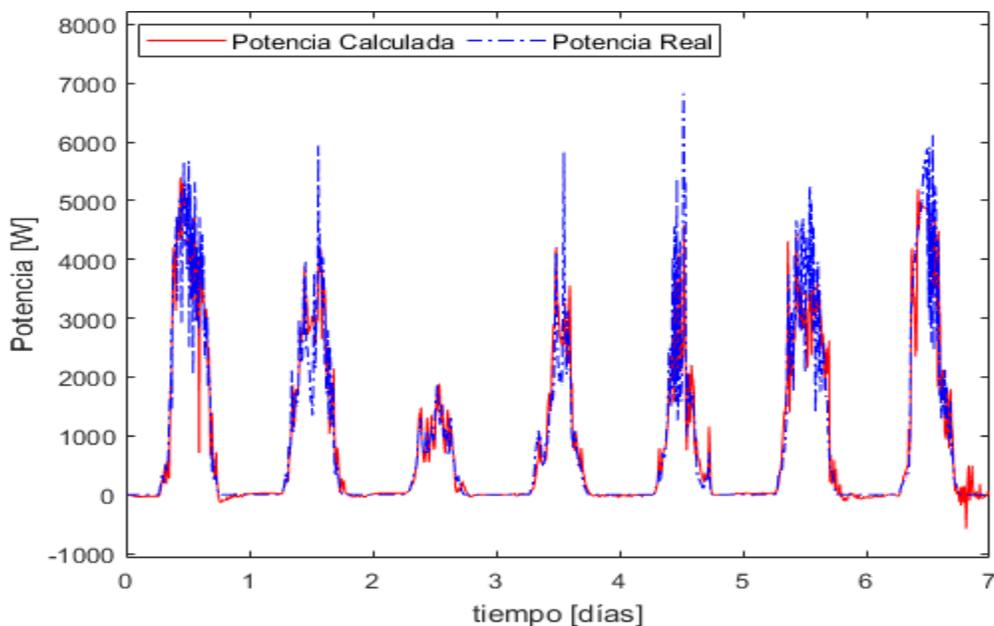


Figura 4.1.3: Resultados perceptrón multicapa caso 1.3

Los resultados obtenidos del caso 1 se muestran en la Tabla 4.1.2 donde se encuentra que la arquitectura de 15 neuronas en la capa oculta, tiene un error bajo, tomando en cuenta el tiempo de entrenamiento de la red neuronal. De acuerdo al resultado de este análisis de variación del número de neuronas en la capa oculta, se tomará para los casos posteriores, 15 neuronas en la capa oculta. Se ha tomado en cuenta la generalización de la red, por lo tanto, se ha seleccionado una red lo suficientemente grande para proporcionar un ajuste adecuado. Por ejemplo, cuanto mayor sea la red que se utilice, serán más complejas las relaciones que se puedan crear, entonces, el utilizar una red lo suficientemente pequeña, no tendrá suficiente potencia para sobrecargar los datos o sobre entrenarse.

Caso 2: Variación de división de datos para entrenamiento, validación, pruebas.

En la Figura 4.1.4 se muestra el resultado del caso 2.3, el cual emplea 70% de los datos para entrenamiento, 15% para validación y 15% para la prueba. Para este caso el error cuadrático medio alcanza un valor de 4.03×10^{-3} . En la Figura 4.1.5 se muestra el resultado del caso 2.8, el cual emplea 10% de los datos para entrenamiento, 45% para validación y 45% para la prueba, Para este caso el error cuadrático medio alcanza un valor de 8.05×10^{-3} .

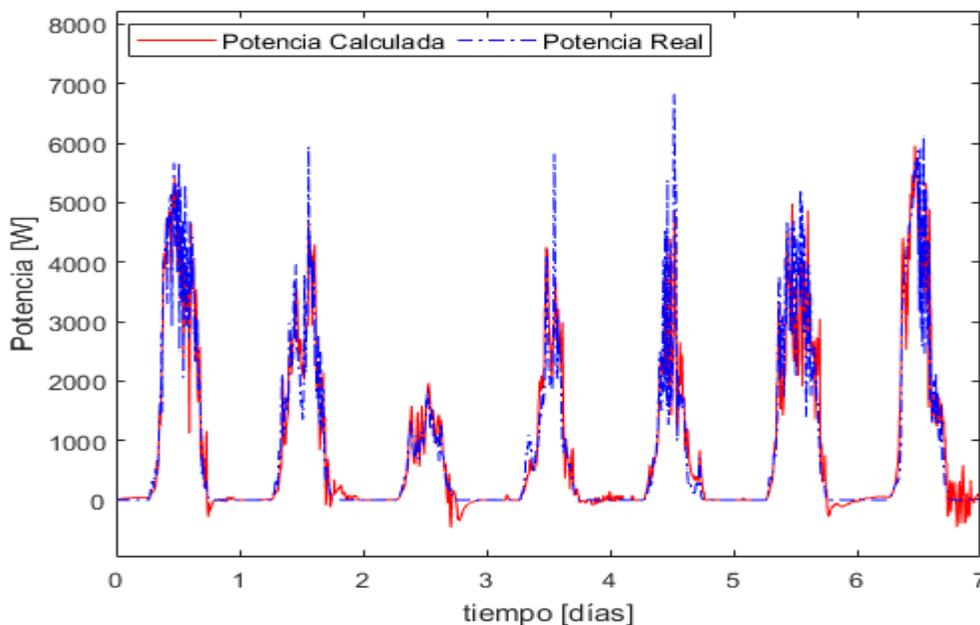


Figura 4.1.4: Resultados perceptrón multicapa caso 2.3.

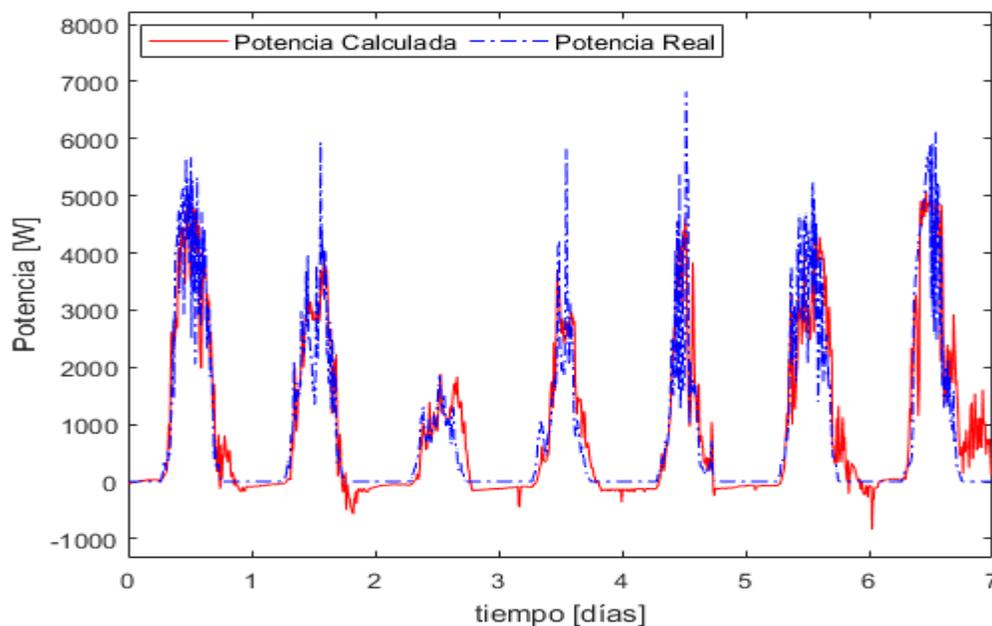


Figura 4.1.5: Resultados perceptrón multicapa caso 2.9.

Los resultados obtenidos del caso 2 se muestran en la Tabla 4.1.2 donde se encuentra que la variación del porcentaje de datos usados para entrenamiento, validación y prueba, arroja diferentes resultados del error cuadrático medio. Se encontraron los mejores resultados con una división de datos del 70, 15 y 15 por ciento. Por lo tanto, se tomará esta división de porcentaje de datos para los casos posteriores.

Caso 3: Variación de días de cantidad de datos de entrada.

En la Figura 4.1.6 se muestra el resultado del caso 3.1, el cual emplea 7 días como datos de entrada. Para este caso el error cuadrático medio alcanza un valor de 4.99×10^{-3} . En la Figura 4.1.7 se muestra el resultado del caso 3.9, el cual emplea 168 días como datos de entrada. Para este caso el error cuadrático medio alcanza un valor de 8.37×10^{-3} .

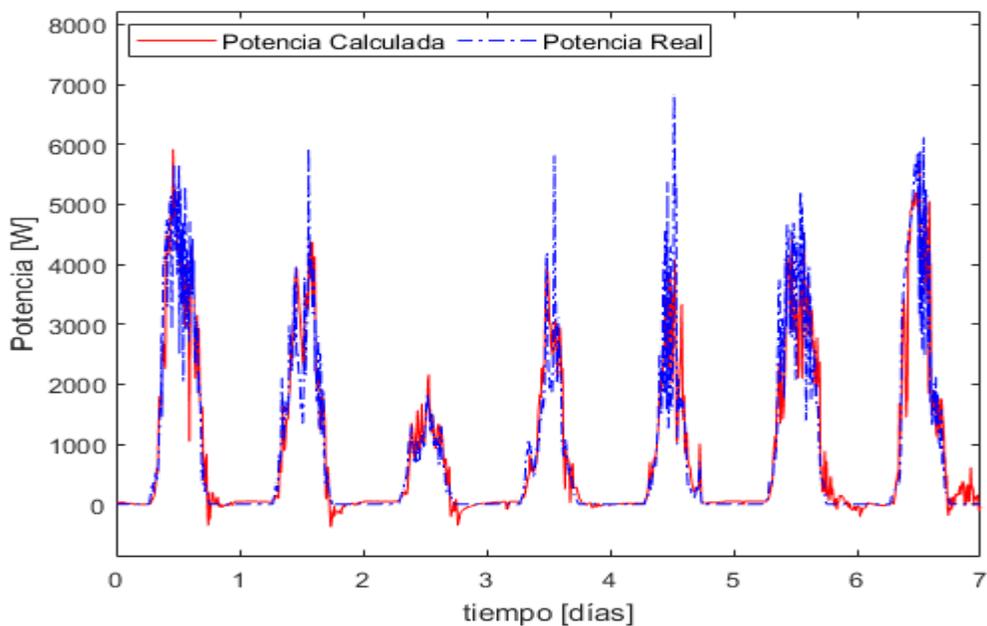


Figura 4.1.6: Resultados perceptrón multicapa caso 3.1.

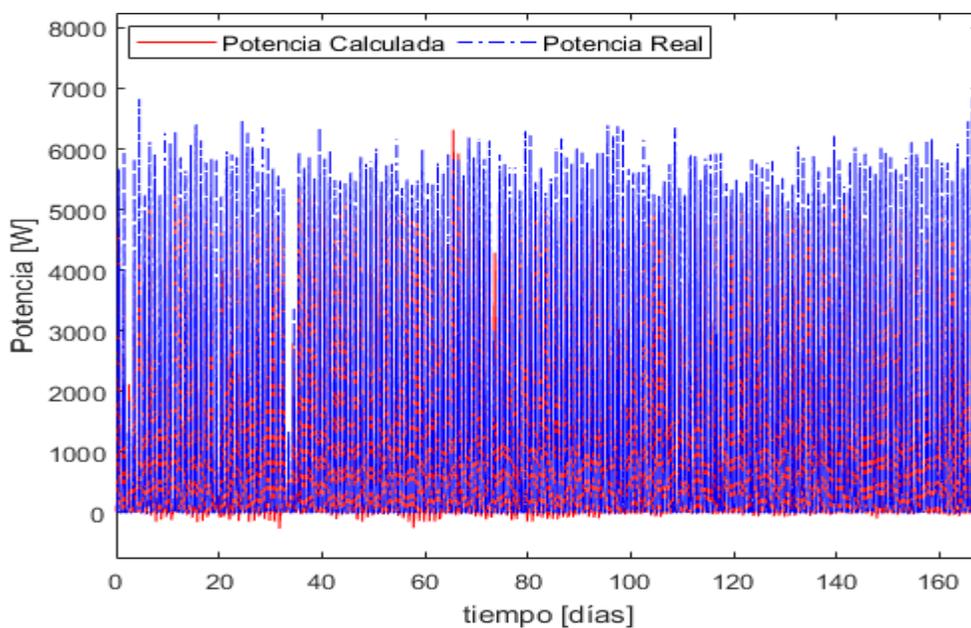


Figura 4.1.7: Resultados perceptrón multicapa caso 3.9.

Los resultados obtenidos del caso 3 se muestran en la Tabla 4.1.2 donde se modifica el número de días empleados (datos) como entrada de la red neuronal. Se encuentra el menor error cuadrático medio para datos de 7 días. Los cuales se usarán para los siguientes casos.

Se observa que aumentar el tamaño del conjunto de datos de entrenamiento no disminuye el error cuadrático medio. Esto es debido a que una mayor cantidad de datos no siempre ayuda a superar las suposiciones del método de modelado. Se tienen como suposiciones, que la potencia producida de un arreglo FV puede ser aproximada mediante una estructura neuronal del tipo percepción multicapa, no recurrente, con cuatro variables de entrada. Al no conocer todo el proceso subyacente del modelo, se tiene un modelo aproximado, lo cual no limita su utilidad.

Caso 4: Variación de días de cantidad de retardos de entrada.

En la Figura 4.1.8 se muestra el resultado del caso 4.3, el cual emplea 6 retardos a las entradas. Para este caso el error cuadrático medio alcanza un valor de 6.16×10^{-3} . En la Figura 4.1.9 se muestra el resultado del caso 4.9, el cual emplea 12 retardos a las entradas. Para este caso el error cuadrático medio alcanza un valor de 7.39×10^{-3} .

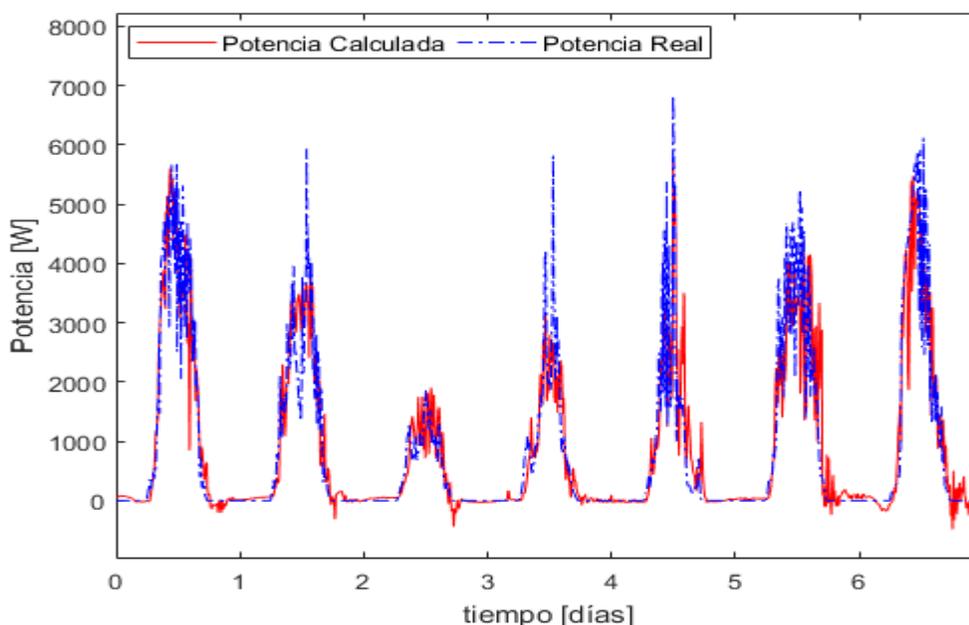


Figura 4.1.8: Resultados perceptrón multicapa caso 4.3.

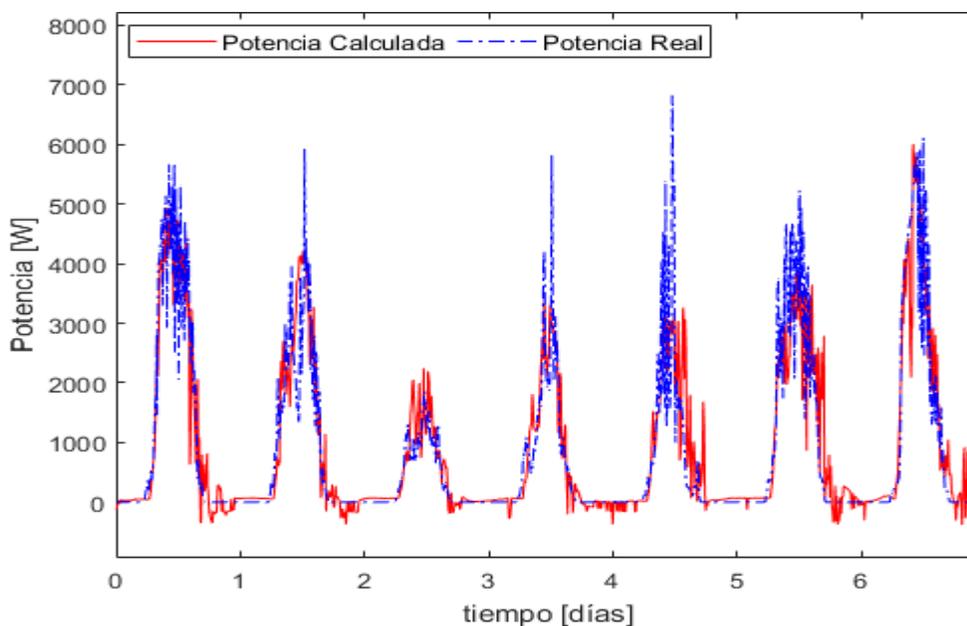


Figura 4.1.9: Resultados perceptrón multicapa caso 4.9.

Los resultados obtenidos del caso 4 se muestran en la Tabla 4.1.2 donde se modifica el número retardos a las entradas de la red neuronal. Los retardos van desde 4 a 12 por igual para las cuatro entradas. Se encuentra el menor error cuadrático medio para 6 retardos a las entradas empleadas. Este resultado concuerda con las correlaciones cruzadas calculadas, ya que son 6 retrasos de tiempo necesarios, de temperatura y 5 de humedad, para pronosticar la potencia. Aumentar la cantidad de retrasos de tiempo a las entradas, no aporta información útil y tiende a aumentar el error.

Caso 5: Variación del horizonte de predicción.

En la Figura 4.1.10 se muestra el resultado del caso 5.3, el cual emplea 6 retardos a las entradas. Para este caso el error cuadrático medio alcanza un valor de 6.16×10^{-3} . En la Figura 4.1.11 se muestra el resultado del caso 5.6, el cual emplea 12 retardos a las entradas. Para este caso el error cuadrático medio alcanza un valor de 7.39×10^{-3} .

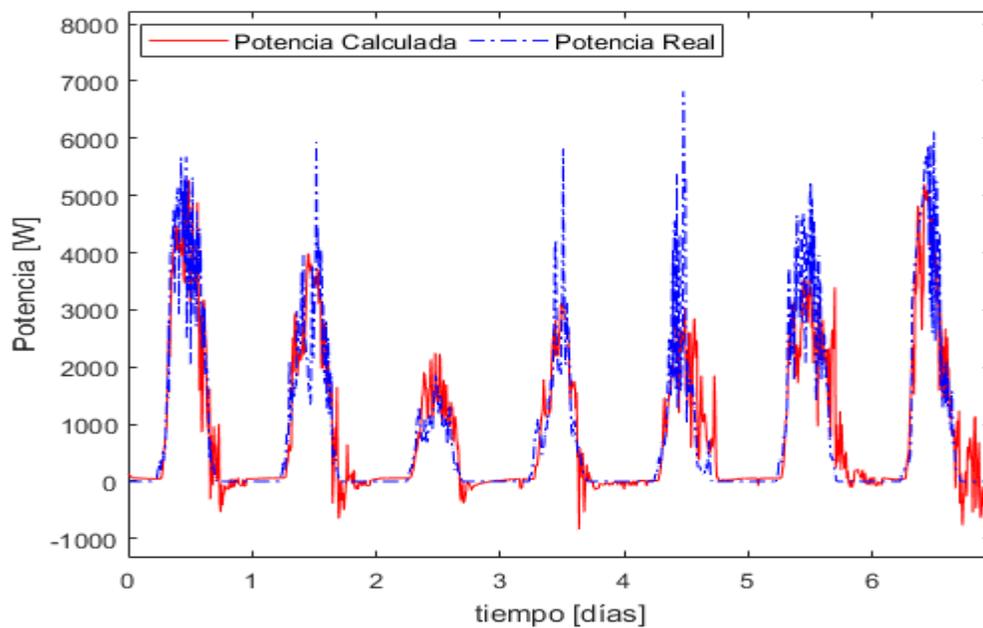


Figura 4.1.10: Resultados perceptrón multicapa caso 5.3.

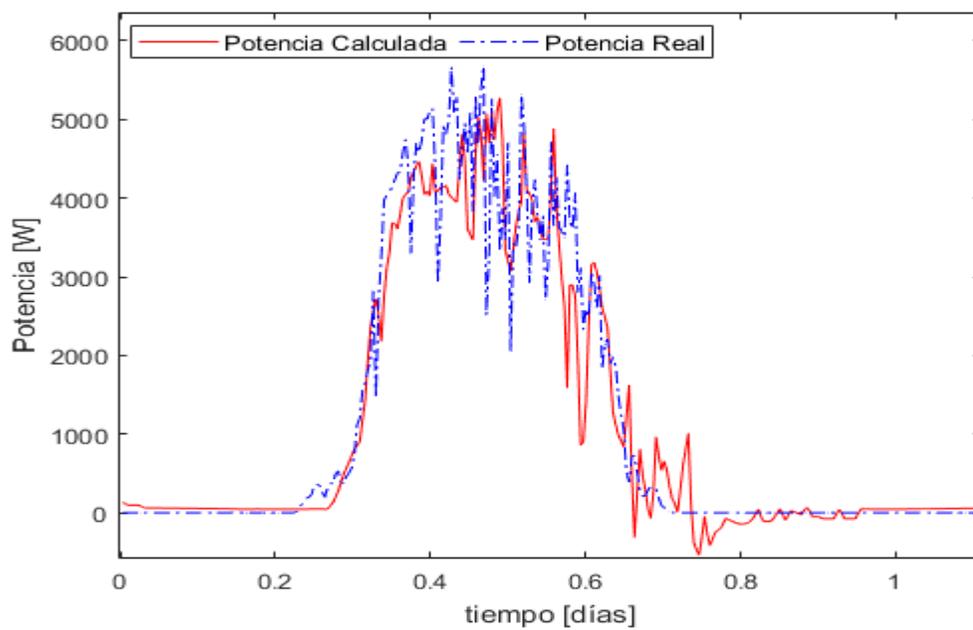


Figura 4.1.11: Detalle de predicción perceptrón multicapa caso 5.3.

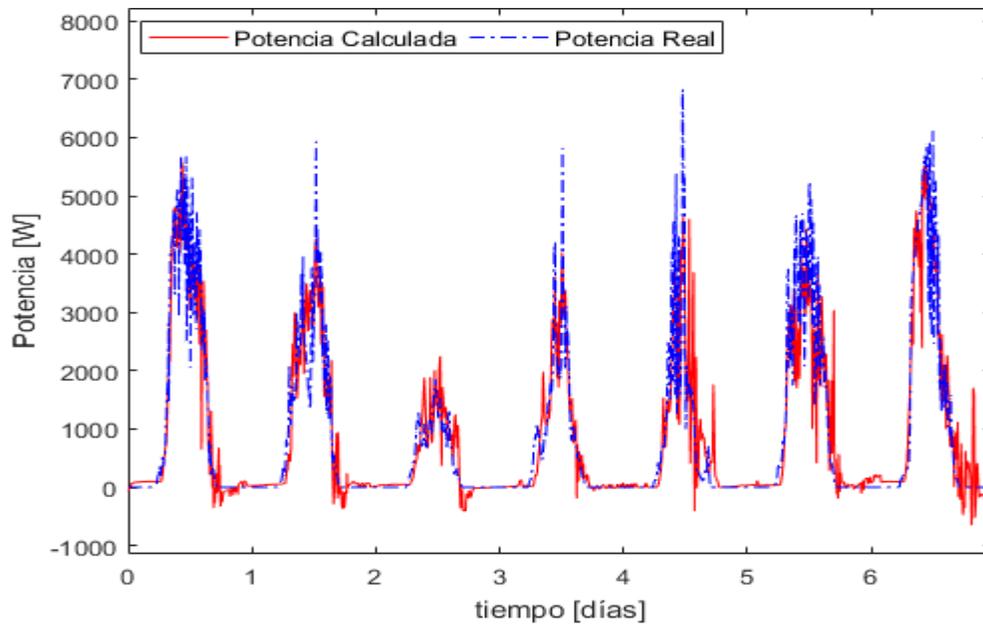


Figura 4.1.12: Resultados perceptrón multicapa caso 5.6.

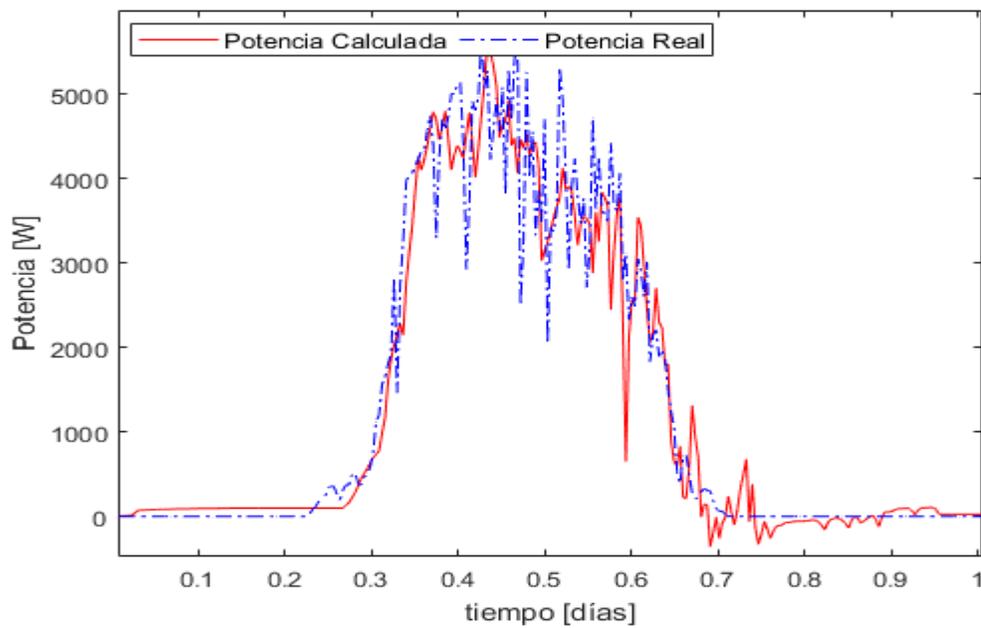


Figura 4.1.13: Detalle de predicción perceptrón multicapa caso 5.6.

Los resultados obtenidos del caso 5 se muestran en la Tabla 4.1.2 donde se varía el horizonte de predicción desde 1 hasta 9. Se encuentra el menor error para seis pasos hacia adelante en el tiempo. El error aumenta cuando el horizonte de predicción aumenta, esto puede ser debido a que el tipo de red empleada no es especializada.

Caso 6: Variación de cantidad de retardos de la entrada de radiación solar.

En la Figura 4.1.14 se muestra el resultado del caso 6.1, el cual emplea 6 retardos a la entrada de radiación solar. Para este caso el error cuadrático medio alcanza un valor de 4.79×10^{-3} . En la Figura 4.1.5 se muestra el resultado del caso 6.6, el cual emplea 6 retardos a la entrada de radiación solar. Para este caso el error cuadrático medio alcanza un valor de 3.9×10^{-3} .

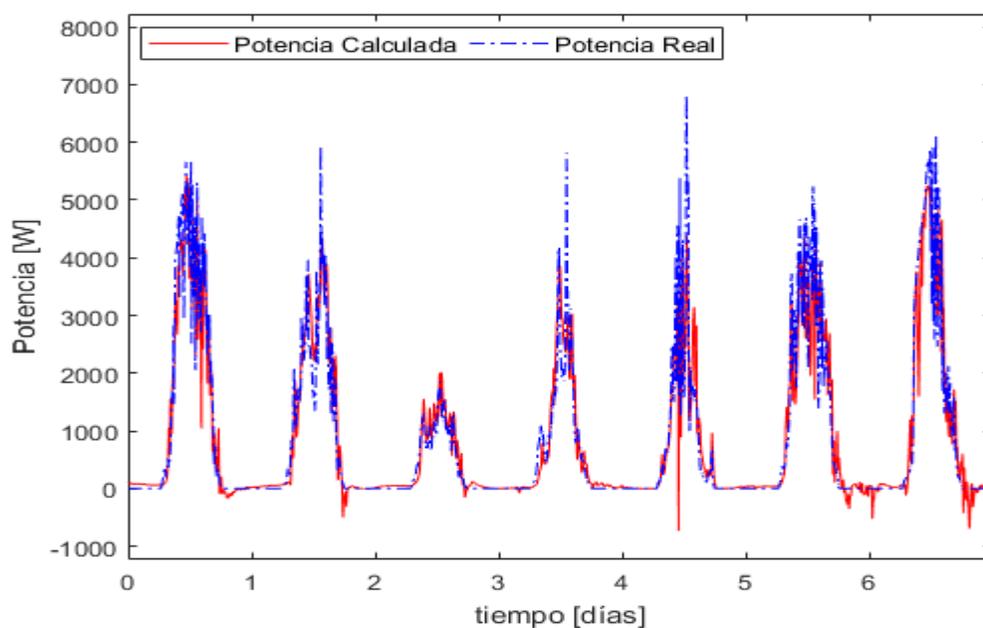


Figura 4.1.14: Resultados perceptrón multicapa caso 6.1.

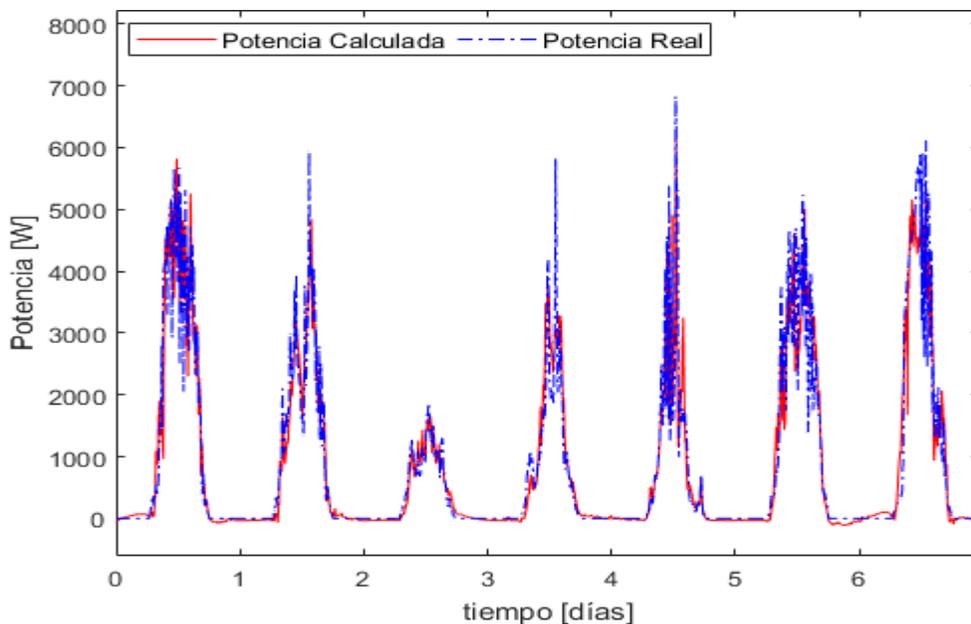


Figura 4.1.15: Resultados perceptrón multicapa caso 6.6.

En la Figura 4.1.16 se muestra el resultado del caso 6.8, el cual emplea 8 retardos a la entrada de radiación solar. Para este caso el error cuadrático medio alcanza un valor de 3.87×10^{-3} , lo cual es un valor bajo comparado con los obtenidos en este caso. Por lo observado, el error cuadrático medio no es suficiente para evaluar la predicción, ya que aun teniendo un valor bajo, puede existir un comportamiento no adecuado.

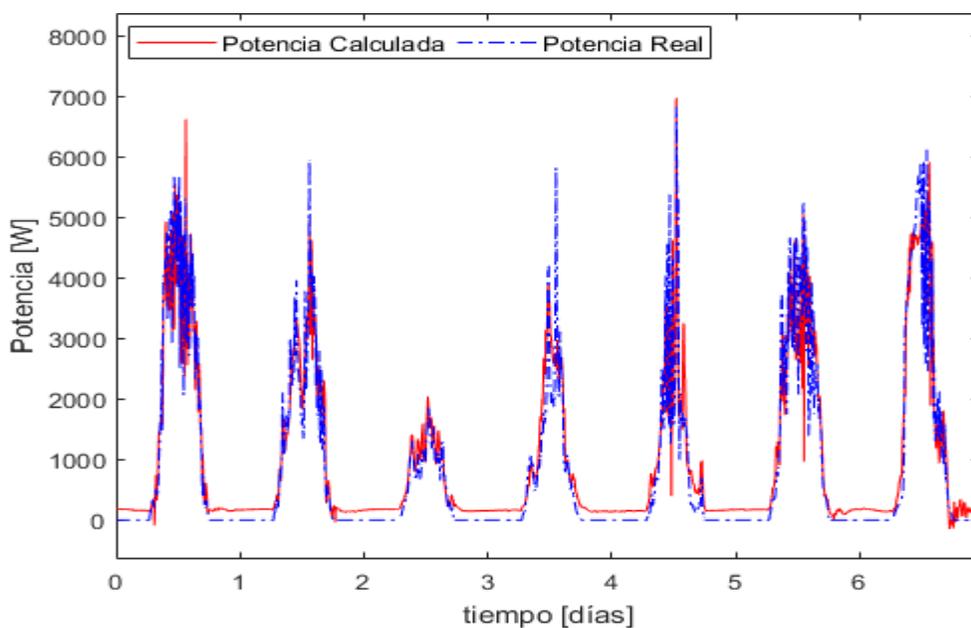


Figura 4.1.16: Resultados perceptrón multicapa caso 6.8.

Los resultados obtenidos del caso 6 se muestran en la Tabla 4.1.2 donde varia el horizonte de predicción, se encuentra el menor error para seis pasos hacia adelante en el tiempo.

Tabla 4.1.2: Resumen de parámetros y resultados para perceptrón multicapa.

Caso	Datos (días)	Entrenamiento (%)	Validación (%)	Prueba (%)	Variables de entrada	Retardo entrada	Predicción	Arquitectura (neuronas)	MSE (1x10 ⁻³)	Tiempo (s)
1.1	7	70	15	15	R,T,H,V	0	0	5-1	6.12	0.157
1.2								10-1	5.45	0.219
1.3								15-1	4.08	0.375
1.4								20-1	4.24	0.422
1.5								30-1	4.34	0.328
1.6								50-1	4.26	0.36
1.7								100-1	3.89	1.06
1.8								150-1	3.66	2.35
1.9								200-1	3.4	4.14
2.1	7	90	5	5	R,T,H,V	0	0	15-1	4.8	0.312
2.2		80	10	10					4.61	0.281
2.3		70	15	15					4.03	0.469
2.4		60	20	20					4.84	0.313
2.5		50	25	25					5.1	0.25
2.6		40	30	30					5.42	0.187
2.7		30	35	35					6.74	0.156
2.8		20	40	40					6.53	0.172
2.9		10	45	45					8.05	0.234
3.1	7	70	15	15	R,T,H,V	0	0	15-1	4.99	0.375
3.2	14								8.07	0.219
3.3	28								7.91	0.906
3.4	42								7.65	1.54
3.5	94								7.6	1.46
3.6	112								7.83	5.93
3.7	130								7.93	11.9
3.8	150								8.06	2.87
3.9	168								8.37	6.89
4.1	7	70	15	15	R,T,H,V	4	0	15-1	6.3	0.282
4.2						5			6.58	0.25
4.3						6			6.16	0.234
4.4						7			6.8	0.219
4.5						8			6.46	0.375
4.6						9			8.35	0.172
4.7						10			7.13	0.25
4.8						11			6.68	0.281
4.9						12			7.39	0.218
5.1	7	70	15	15	R,T,H,V	12	1	15-1	6.41	0.453
5.2							2		7.38	0.359
5.3							3		8.27	0.219
5.4							4		7.05	0.391
5.5							5		7.01	0.36
5.6							6		6.04	0.25
5.7							7		8.59	0.172
5.8							8		6.57	0.484
5.9							9		8.03	0.234
6.1	7	70	15	15	R,T,H,V	Rad=1	0	15-1	4.79	0.406
6.2						Rad=2			4.47	0.297
6.3						Rad=3			4.06	0.406
6.4						Rad=4			4.18	0.219
6.5						Rad=5			4.11	0.204
6.6						Rad=6			3.9	0.172
6.7						Rad=7			4.13	0.187
6.8						Rad=8			3.87	0.203
6.9						Rad=9			4.27	0.172

4.2 Red neuronal de alto orden

Se procede a emplear una red neuronal de alto orden entrenada con el filtro extendido de Kalman, como la que se muestra en la Figura 4.2.1.

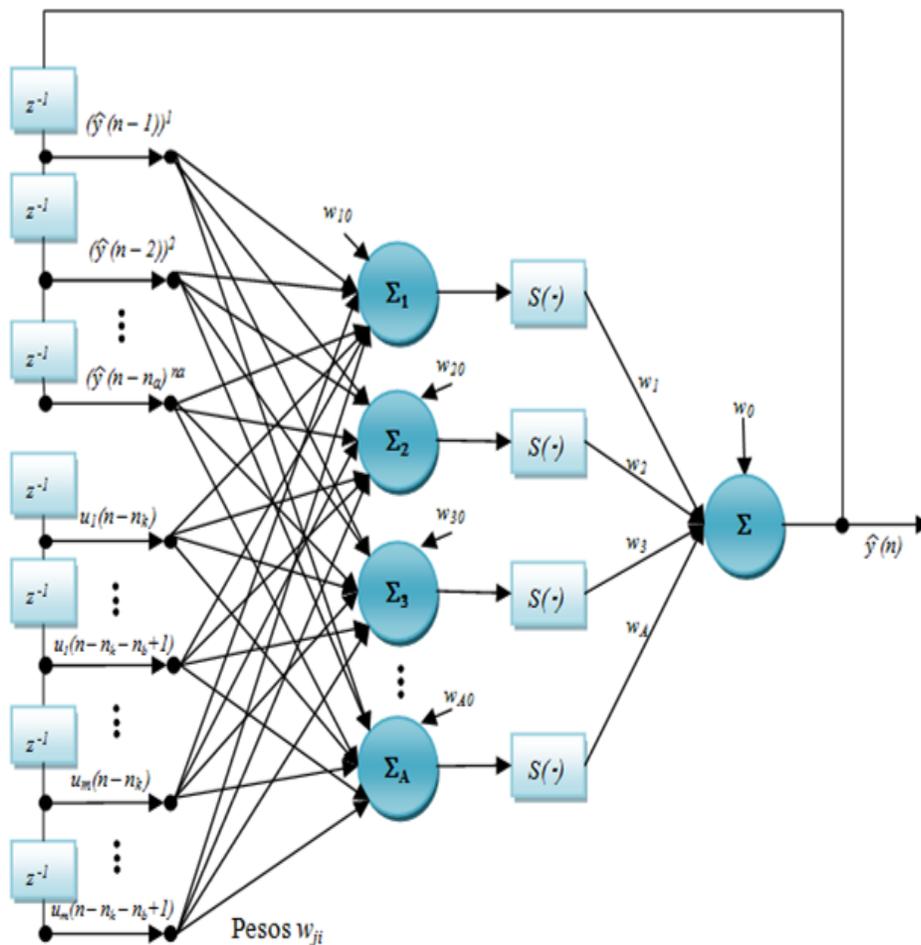


Figura 4.2.1. Red neuronal de alto orden recurrente diseñada.

Se seleccionaron 6 entradas de potencia pasadas, que se incluyen en el vector de entrada de la red neuronal para la energía fotovoltaica. Para entrenar a la red se tienen cuatro entradas externas correspondientes al arreglo de irradiación, temperatura, humedad relativa y velocidad de viento, 15 elementos en la capa oculta, 1 neurona en la capa de salida y 200 iteraciones como máximo. Se tiene como resultado las gráficas mostradas en la Figura 4.2.2. de aquí se puede apreciar un mejor ajuste en los valores de potencia cero y cercanos a cero.

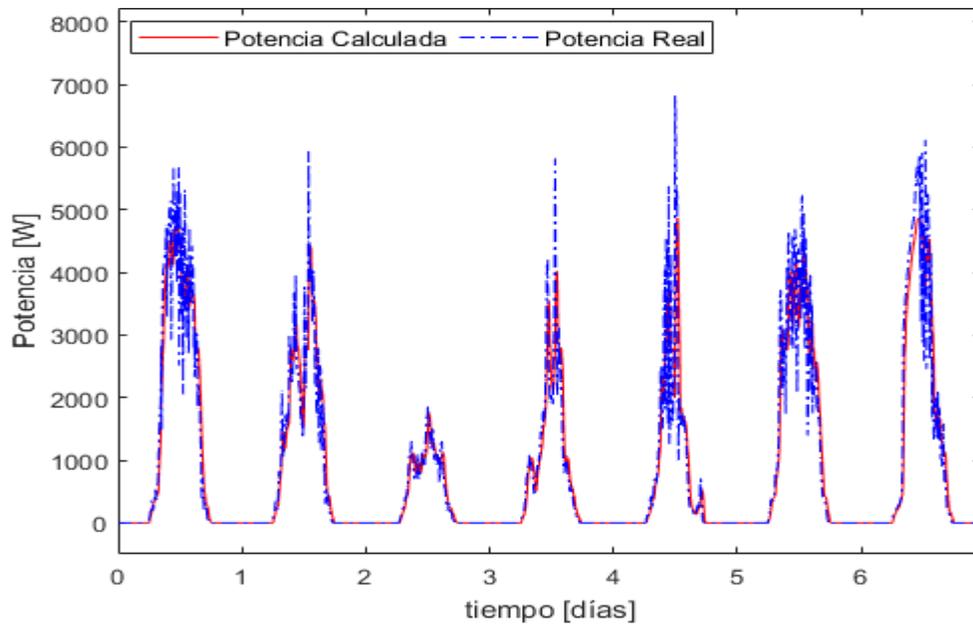


Figura 4.2.2: Resultado de red neuronal recurrente de alto orden caso 1.

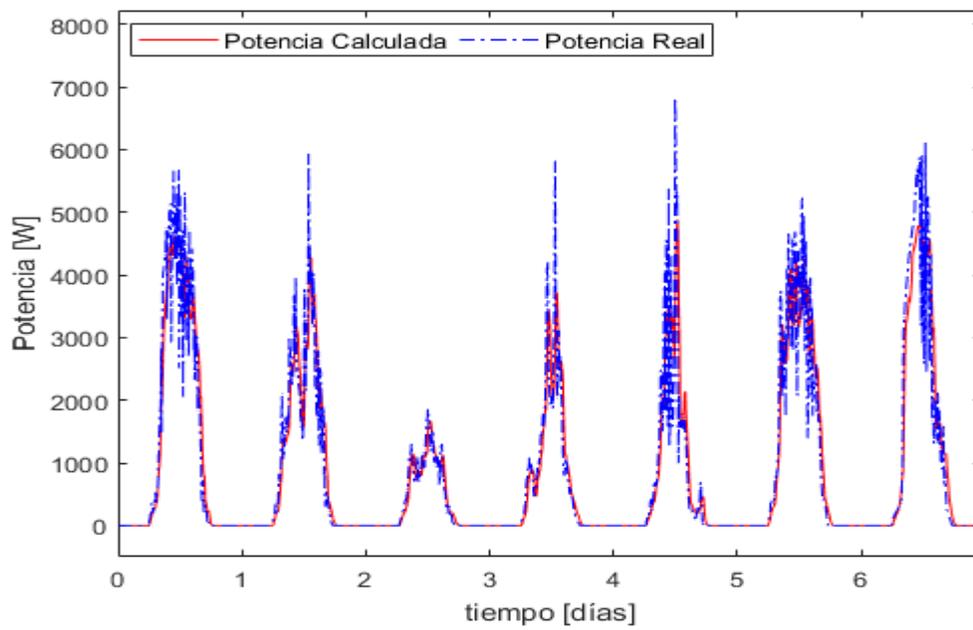


Figura 4.2.3: Resultado de red neuronal recurrente de alto orden caso 2.

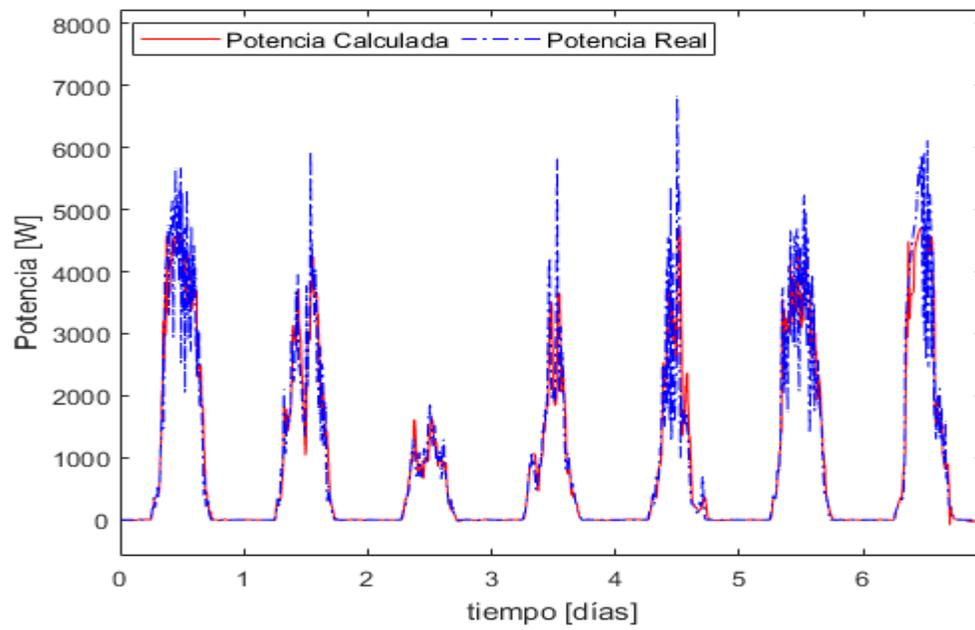


Figura 4.2.4: Resultado de red neuronal recurrente de alto orden caso 3.

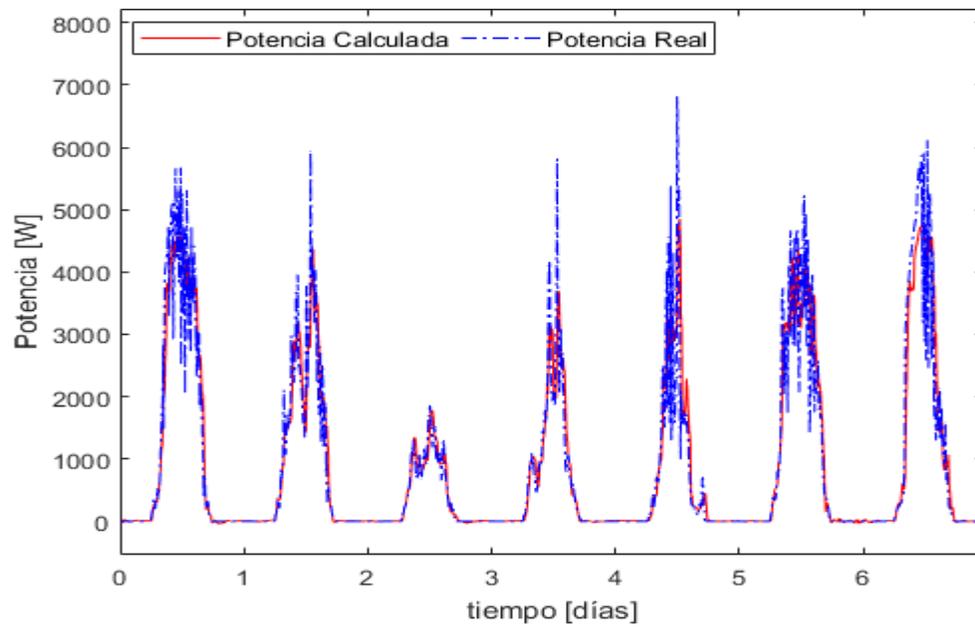


Figura 4.2.5: Resultado de red neuronal recurrente de alto orden caso 4.

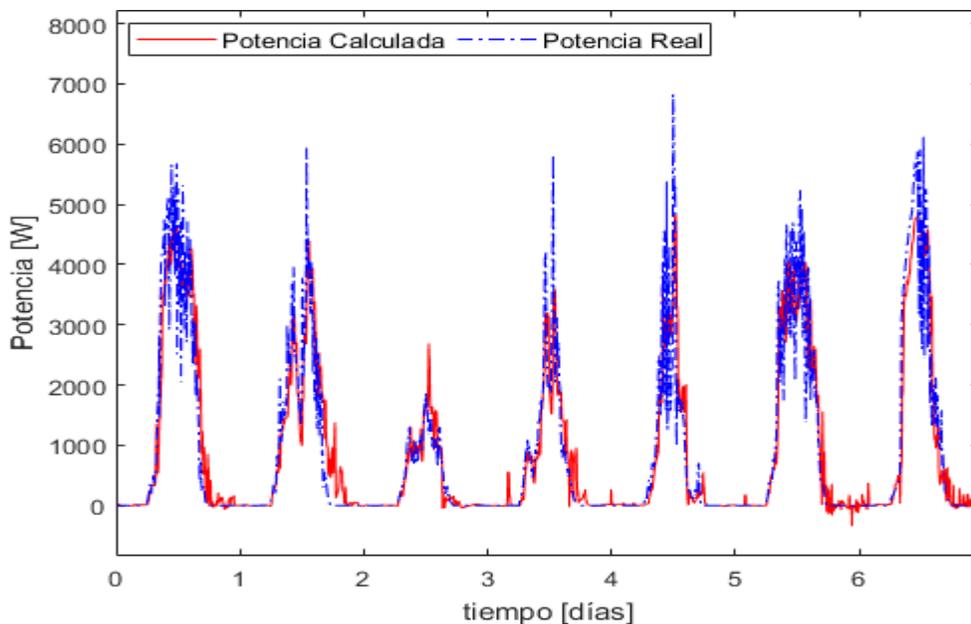


Figura 4.2.6: Resultado de red neuronal recurrente de alto orden caso 5.

En la Tabla 4.2.1 se muestran los resultados de las pruebas de la red neuronal de alto orden entrenada con el filtro extendido de Kalman.

Tabla 4.2.1: Errores en la predicción de red neuronal recurrente de alto orden.

Variables de entrada	MSE
P	2.62×10^{-3}
P, R	2.53×10^{-3}
P, R, T	2.40×10^{-3}
P, R, T, H	2.51×10^{-3}
P, R, T, H, V	3.21×10^{-3}

Con el objetivo de comparar la red neuronal de alto orden con el perceptrón multicapa empleado anteriormente, se procede a eliminar la variable potencia de la red recurrente.

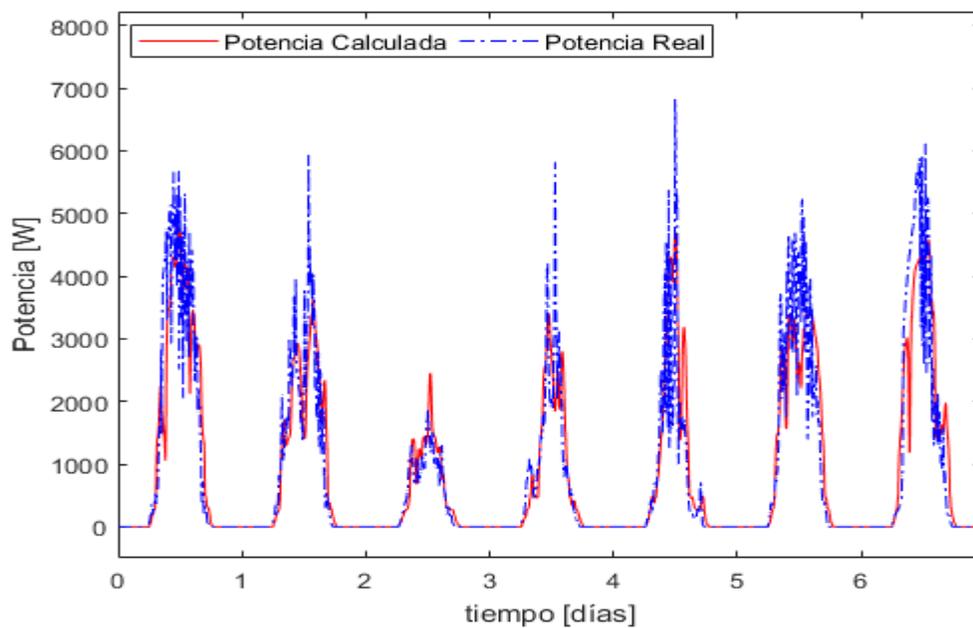


Figura 4.2.7: Resultado red neuronal alto orden caso 1.

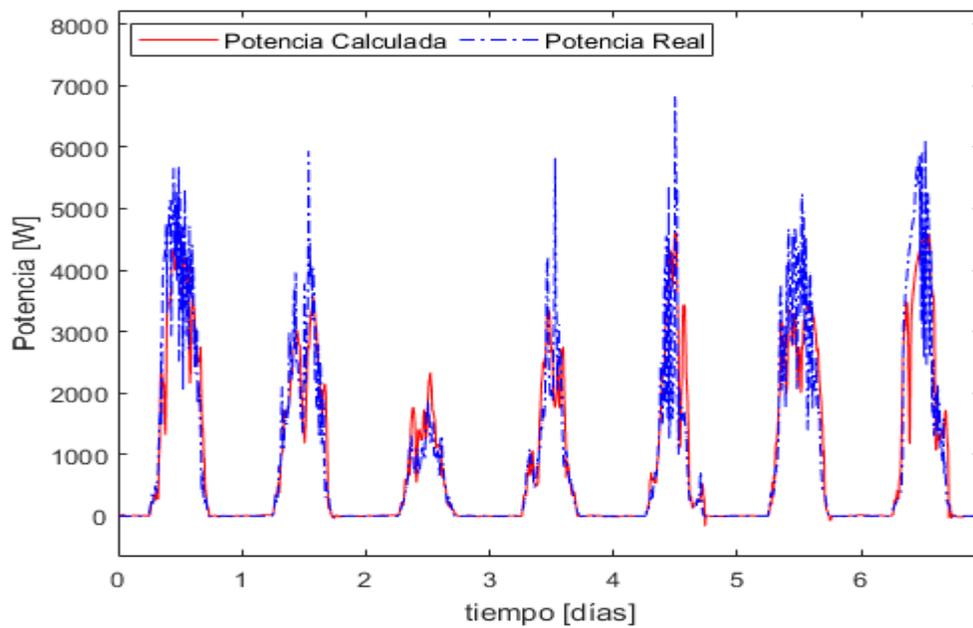


Figura 4.2.8: Resultado red neuronal alto orden caso 2.

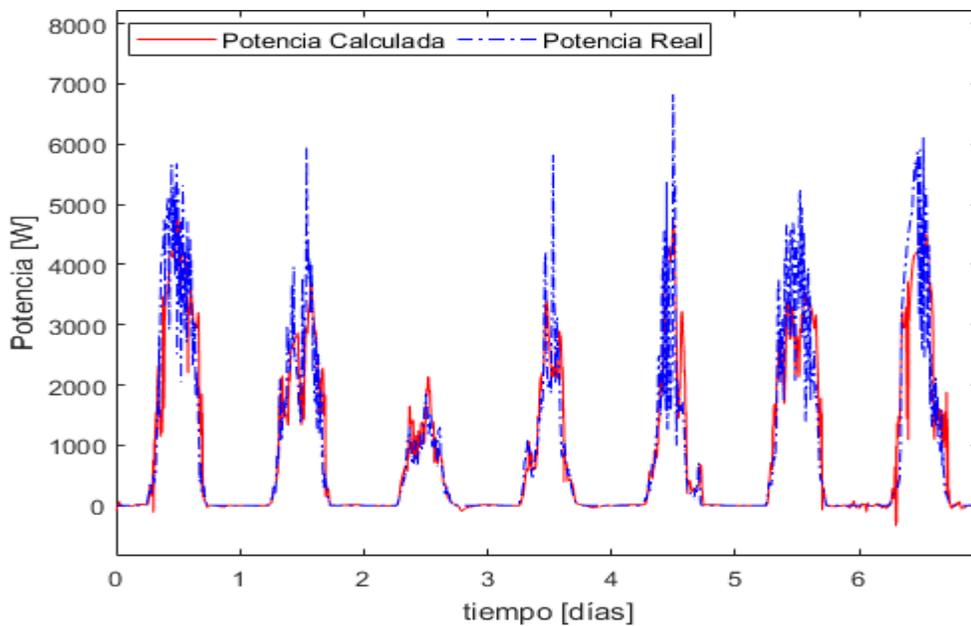


Figura 4.2.9: Resultado red neuronal alto orden caso 3

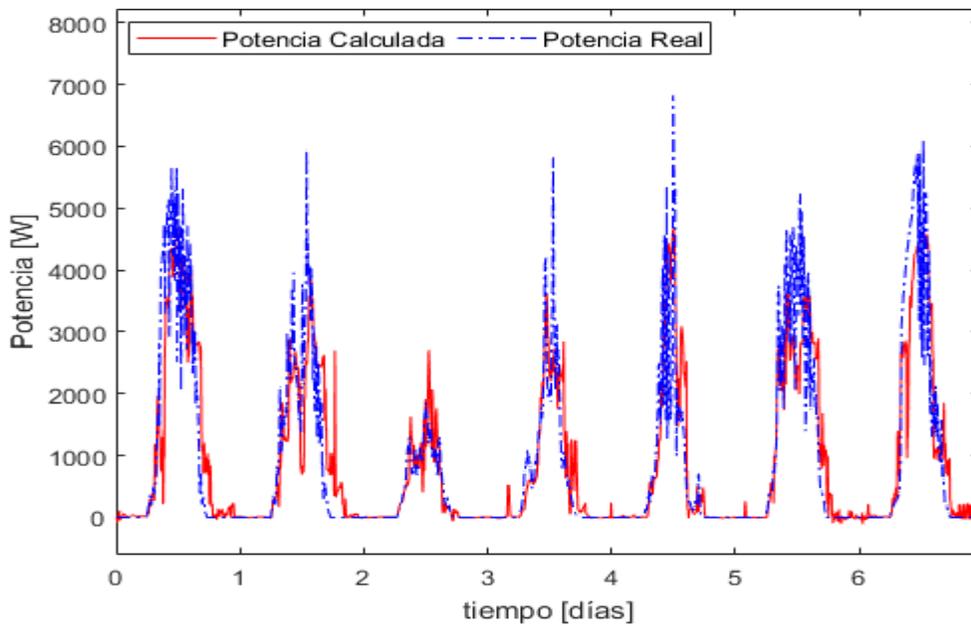


Figura 4.2.10: Resultado red neuronal alto orden caso 4.

Tabla 4.2.2: Errores en la predicción de red neuronal de alto orden.

Variables de entrada	MSE
R	4.09×10^{-3}
R, T	3.82×10^{-3}
R, T, H	3.83×10^{-3}
R, T, H, V	5.02×10^{-3}

4.3 Análisis comparativo de resultados

Se procede a comparar los resultados obtenidos, se puede observar que para el perceptrón multicapa, se tienen un número de neuronas casi óptimo en 20, lo cual concuerda con las arquitecturas revisadas en la literatura en el cual ronda a 15 en todos los casos.

Se puede observar de manera gráfica en las Figura 4.1.4 y Figura 4.2.2 la aproximación más cercana a los datos de potencia con valor de 0 en el caso de la red neuronal de alto orden entrenada mediante el filtro extendido de Kalman.

Tabla 4.3.1: Evaluación del error para diferentes modelos

Entradas, salida y capas ocultas	Arquitectura	MSE
Perceptrón multicapa		
F[R,T,H,V]	15-1	4.08×10^{-3}
F[R,T,H,V] Retardo 6	15-1	6.16×10^{-3}
F[R,T,H,V] Predicción 6	15-1	6.04×10^{-3}
F[R,T,H,V] Retardo de radiación solar 6	15-1	3.9×10^{-3}
Red recurrente de alto orden		
F[P] 6 retardos de potencia	15-1	2.62×10^{-3}
F[P,R] 6 retardos de potencia	15-1	2.53×10^{-3}
F[P,R,T] 6 retardos de potencia	15-1	2.40×10^{-3}
F[P,R,T,H] 6 retardos de potencia	15-1	2.51×10^{-3}
F[P,R,T,H,V] 6 retardos de potencia	15-1	3.21×10^{-3}
Red neuronal alto orden		
F[R] 6 Retardos de Radiación	15-1	4.09×10^{-3}
F[R,T] 6 Retardos de Radiación	15-1	3.82×10^{-3}
F[R,T,H] 6 Retardos de Radiación	15-1	3.83×10^{-3}
F[R,T,H,V] 6 Retardos de Radiación	15-1	5.02×10^{-3}

5. ASPECTOS DE IMPLEMENTACIÓN

Para que el resultado de este trabajo puede llevarse a la práctica, se tomarán en cuenta algunos de los aspectos necesarios. La medida de la potencia producida de un módulo fotovoltaico o un conjunto de ellos, normalmente implica el uso de costosos sistemas de medida que suelen quedar fuera del alcance del propietario de una pequeña instalación solar. Sin duda, es necesario en estos casos el uso de un sistema de precisión suficiente y de bajo costo para la determinación en campo de la potencia producida. Para ello se requiere el diseño de dos módulos electrónicos. Se presenta en la Figura 5.1.1 un diagrama esquemático del sistema a desarrollar.

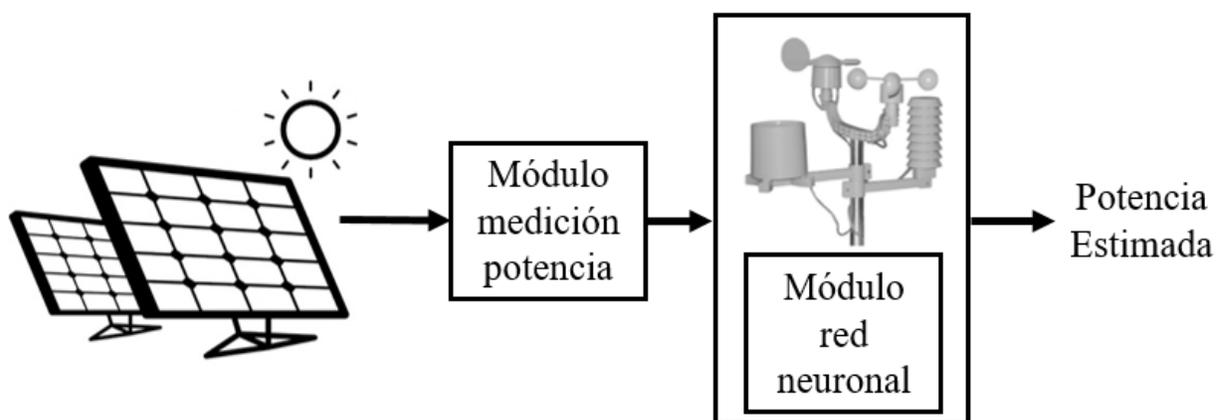


Figura 5.1.1: Diagrama de implementación.

El primer módulo servirá para la medición de potencia del arreglo de paneles fotovoltaicos, este consiste en un sistema de medición que muestrea simultáneamente las señales de tensión y corriente para obtener la potencia. El segundo módulo (neuronal) tomará las mediciones de potencia del primer módulo, medirá las variables meteorológicas mediante instrumentos y entrenará a la red neuronal. Este mismo módulo se mantendrá en el sitio para llevar a cabo la predicción de potencia, usando únicamente datos meteorológicos. Por el contrario, el primer módulo solo se mantendrá en el sitio por un lapso de siete días.

Cabe mencionar que ambos módulos tienen componentes internos y externos, los cuales deberán ser durables, resistentes a la corrosión y condiciones extremas. Como componentes externos se necesitarían gabinetes, pantallas LCD y teclados matriciales para ambos módulos. Se emplearán sensores de voltaje y corriente, las variables almacenadas se multiplicarán y se tendrá la potencia producida. Se utilizarán dos unidades de procesamiento, para el primer módulo se haría uso de un dsPIC, el cual es un controlador digital de señales, dotados de recursos físicos y lógicos necesarios para poder soportar las aplicaciones específicas del procesamiento digital de señales. Este módulo debe encargarse de obtener los datos de los sensores, calcular la potencia instantánea y almacenar los datos. La segunda unidad de procesamiento será para el segundo módulo, para el cual se dispondrá de un FPGA (Field Programmable Gate Array) el cual es un dispositivo programable que contiene bloques de lógica integrados en gran escala. Estos dispositivos sobrellevan los inconvenientes de implementación en hardware, como, gran cantidad de multiplicaciones y sumas de varios elementos. Finalmente se toma en cuenta la facilidad de exportar el trabajo realizado debido a la utilización del entorno de programación usado, ya que Xilinx System Generator (XSG) utiliza Simulink, como entorno de desarrollo y se hace presente en forma de blockset.

6. CONCLUSIONES

En el presente trabajo se diseñó e implementó un algoritmo para predecir la serie de tiempo de la potencia producida mediante un sistema de arreglos fotovoltaicos, usando tres arquitecturas de redes neuronales, con diferentes tipos de entrenamiento para obtener un error de estimación mínimo en la predicción de la variable de interés.

Este trabajo fue motivado dado que la energía renovable ha tenido un aumento significativo en la estructura energética mundial donde los sistemas fotovoltaicos han demostrado un rápido desarrollo y grandes beneficios. Se prevén grandes sistemas de producción fotovoltaicos, así como un gran impacto en los sistemas de energía ya existentes.

Finalmente, se establece que la predicción de potencia en los sistemas de generación de energía fotovoltaica es dependiente de las condiciones meteorológicas y de la obtención de un modelo que represente esta influencia, para el análisis de fallas, mantenimiento y control de la generación.

Así mismo, se obtuvieron datos de potencia producida por el arreglo de paneles fotovoltaicos y mediciones de variables meteorológicas. Después de la captura y procesamiento de los archivos de datos, se obtuvo la serie de tiempo de la producción de potencia y la serie de tiempo de datos meteorológicos. Mediante métodos descriptivos se analizaron tablas y gráficos para los datos de las series de tiempo. Se realizó un análisis para analizar la correlación que existe entre la potencia producida (variable dependiente) y las variables independientes de radiación solar, velocidad de viento, humedad y temperatura. Se obtuvieron relaciones estadísticamente significativas del coeficiente de correlación entre la variable de potencia y las variables meteorológicas. Se estudió la correlación cruzada, que es la correlación entre una serie en un tiempo dado y otra serie en un tiempo posterior. La correlación cruzada sirvió como herramienta para determinar si la serie de tiempo en un tiempo dado, ayudaría al pronóstico de la otra serie en un tiempo posterior.

Para predecir la potencia se demostró que son estadísticamente significativos retrasos de radiación solar, desde 0 a 19. Los retrasos de temperatura son estadísticamente

significativos de 6 a 20. Los retrasos de humedad relativa son estadísticamente significativos de 5 a 20. Los retrasos de velocidad de viento no fueron significativos.

Para aprovechar la información de la serie de tiempo de la mejor forma posible, se encontró una dimensión del sistema mediante la aplicación de teoría de embebimiento a la serie de tiempo de potencia. El resultado del método de Cao para la serie de tiempo de potencia fue de 6, lo que indica cuantos retrasos deben ser empleados como dimensión mínima para aproximar la función objetivo.

También, se desarrolló un modelo de predicción de generación de potencia mediante un perceptrón multicapa, con algoritmo de entrenamiento Levenberg-Marquardt, para el cual se variaron diferentes parámetros, como son el número de neuronas en la capa oculta, porcentaje de datos destinados al entrenamiento, cantidad de datos de entrada (días), cantidad de retardos a las entradas y horizontes de predicción. Estas diferentes configuraciones formaron un total de 54 casos, de los cuales se obtuvieron los errores cuadráticos medios y el tiempo de entrenamiento. Con base a estos dos parámetros se seleccionó la mejor arquitectura de red neuronal la cual fue de 15 neuronas en la capa oculta.

Igualmente, se desarrolló un segundo modelo de predicción, el cual es una red neuronal recurrente de alto orden entrenada con el filtro extendido de Kalman. Se tuvo una variación en el tipo de entradas a la red, siendo el primero únicamente potencia y después añadiendo cada una de las variables ambientales (radiación, temperatura, humedad y velocidad de viento). Cabe destacar, que se tuvo el mejor desempeño al no tener la velocidad de viento como una entrada.

Finalmente, se desarrolló un tercer modelo de predicción, el cual es una red neuronal de alto orden entrenada con el filtro extendido de Kalman. Se tuvo una variación en el tipo de entradas a la red, siendo primero únicamente radiación y después añadiendo cada una de las variables ambientales (temperatura, humedad y velocidad de viento). Se tuvo el mejor desempeño al tener únicamente la radiación y la temperatura.

Sin lugar a duda, el modelo neuronal de alto orden entrenado con el filtro de Kalman presenta un mejor funcionamiento al perceptrón multicapa, esto es debido al tipo de

entrenamiento y entradas recurrentes. Al aplicar estos cambios en la red y entrenamiento, se reduce el error aproximadamente a la mitad.

Con base a todo lo anterior, los resultados de este trabajo exponen que es posible modelar el comportamiento de generación de potencia mediante redes neuronales artificiales, empleando mediciones meteorológicas. Ante lo mencionado anteriormente, las redes neuronales son una potente herramienta útil para encontrar relaciones fuertemente no lineales de grandes volúmenes de datos y pueden ser usadas en múltiples áreas de la ciencia.

REFERENCIAS

- Altermatt, P., Schenk, A., Heiser, G. (2003). Reassessment of the intrinsic carrier density in crystalline silicon in view of band-gap narrowing. "Journal of Applied Physics", 93, 1598-1604.
- Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de-Pison, F. J., Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. "Solar Energy", 136, 78-111.
- Backlacioglu, T. (2016). Modeling the fuel flow-rate of transport aircraft during flight phases using genetic algorithm-optimized neural networks. "Aerospace Science and Technology", 49, 52-62.
- Castañeda, J., Nieto, M., Ortiz, V. (2013). Análisis y aplicación del filtro de Kalman a una señal con ruido aleatorio. "Scientia et Technica", Universidad Tecnológica de Pereira, Colombia, 18, 267-274.
- Conibeer, G. (2007). Third-generation photovoltaics, "Materials Today", 10, 42-50.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function Mathematics of Control. "Signals and Systems", 1ra Edición, 303–314.
- Deossa, A. (2009), Entrenamiento de Redes Neuronales con Filtros de Kalman, Trabajo dirigido de grado de Licenciatura, Universidad Nacional de Colombia, Medellín, Colombia.
- Duffie, J. Beckham, W. (2013). Solar Engineering of thermal processes, 4ta edición, New Jersey, USA, Jhon Wiley & Sons, Inc.
- Dumitru, C., Gligor, A., Enachescu, C. (2016). Solar Photovoltaic Energy Production Forecast Using Neural Networks. "Procedia Technology", 22, 808-815.
- Grahovac, J., Jokic, A., Dodic, J., Vucurovic, D., Dodic, S. (2016). Modelling and prediction of bioethanol production from intermediates and byproduct of sugar beet processing using neural networks. "Renewable Energy", 85, 953-958.
- Henestroza Orozco, R (2009). Centrales eólicas en el Istmo de Tehuantepec; su impacto ambiental y socioeconómico. "Elementos: Ciencia y cultura", Vol. 16, 2009, 39-44.
- Huerta, A. (2014). Estudio del sistema $In_2S_3Sb_2S_3$ en celdas solares de capa extremadamente delgada. Tesis de maestría, Universidad Autónoma de Nuevo León, México.
- Jiménez, L. (2007). Modelos avanzados para la predicción a corto plazo de la producción eléctrica en parques eólicos. Tesis de doctorado, universidad de la Rioja, España.
- Kabalci, Y., Kabalci E. (2017). Modeling and analysis of a smart grid monitoring system for renewable energy sources. "Solar Energy", 153, 262-275.

Kittel, C. (2005). Introduction to solid state physics. Octava edición. Jhon Wiley & Sons.

Krenzinger, A., Prieb, C.W.M. (2005). Clasificación y Selección de Módulos Fotovoltaicos para una Central Conectada a la Red, "Avances en Energías Renovables y Medio Ambiente", Argentina, 9, 19-23.

Krenzinger, A. (2001). An Algorithm for PV Array Analysis, "Proceedings of the 17th European Photovoltaic Solar Energy Conference", Munich, 816-819.

Leva, S., Dolara, A., Grimaccia, F., Mussetta, M., Ogliari, E. (2015). Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power. "Math. Comput. Simulation" (IMACS).

Mannarino, A., Mantegazza, P. (2015). Nonlinear aerodynamic reduced order modeling by discrete time recurrent neural networks. "Aerospace Science and Technology", 47, 406-419.

Ogliari, E., Dolara, A., Manzolini, G., Leva, S. (2017). Physical and hybrid methods comparison for the day ahead PV output power forecast. "Renewable Energy"

Park, J., Sandberg, I. (1991). Universal Approximation Using Radial-Basis-Function Networks. "Neural Computation", 3, 246-257.

Pedro, H., Coimbra, C. (2012). Assessment of forecasting techniques for solar power production with no exogenous inputs. "Solar Energy", 86, 2017-2028.

Posso, F. (2002). Energía y medio ambiente: pasado, presente y futuro. Parte dos: sistema energético basado en energías alternativas. "Geoenseñanza", 7, 54-73.

Qamar, M., Nadarajah, M., Ekanayake, C. (2016). Review on recent advances in PV output power forecast. "Solar Energy", 136, 125-144.

Quesada, J., Faba, L., Díaz, E., Ordóñez, S. (2014). La biomasa como alternativa al petróleo para la obtención de productos químicos: acetona y etanol como moléculas plataforma. "Avances en Ciencias e Ingeniería", 5, 31-49.

Rafael, F., Silveira, E., Farines, J. (2016). A DTN routing strategy based on neural networks for urban bus transportation system. "Journal of Network and Computer Applications", 64, 216-228.

Robilliard, C. (2009). Generación de electricidad a partir de energía geotérmica. "Ingeniería Industrial", 27, 185-205.

Rosenblatt, F. (1961). Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms. Spartan Books, Washington DC.

Rumelhart, D; Geoffrey E and Williams, R. (1986). Learning Internal Representations by Error Propagation. David E. Rumelhart, James L. McClelland, and the PDP research.

Sánchez, E., Alanís A. (2006). Redes neuronales conceptos fundamentales y aplicaciones a control automático, 1ª edición, Pearson educación, S.A., Madrid, 2006.

Shockley, W., Queisser, H. (1961). Detailed balance limit of efficiency of p-n junction solar cells. "Journal of Applied Physics", 32, 510.

Kabalci, Y., Kabalci E. (2017). Modeling and analysis of a smart grid monitoring system for renewable energy sources. "Solar Energy", 153, 262-275.

Yona, A., Seju, T., Funabashi, T. (2007). Application of Recurrent Neural Network to Short-Term-Ahead Generating Power Forecasting for Photovoltaic System. "Power Engineering Society General Meeting", IEEE, Tampa, FL, USA, 1-6.

Würfel, P. (2005). Physics of solar cells, from principles to new concepts. 1ª edición. Jhon Wiley & Sons.

Zheng, W., Chen Y., Huo, M., Zhao, B. (2011). An overview: the development of prediction technology of wind and fotovoltaic power generation. "Energy procedia", 12, 2011.