



Centro de Investigación Científica de Yucatán, A.C.

Posgrado en Energía Renovable.

**“ADMINISTRACIÓN DE FLUJO DE POTENCIA ENTRE
SISTEMAS HÍBRIDOS FOTOVOLTAICO-CELDA DE
COMBUSTIBLE Y EL ALMACENAMIENTO POR MEDIO
DE REDES NEURONALES DE ALTO ORDEN”**

Tesis que presenta:

ING. ERIKA HAYDEÉ RUBIO CÁMARA

En opción al título de

**MAESTRO EN CIENCIAS EN ENERGÍAS
RENOVABLES**

MÉRIDA, YUC. OCTUBRE 2016

AGRADECIMIENTOS

Al CONACyT por la beca nacional con número 500049 brindada para llevar a cabo mis estudios de maestría.

Al CICY y a la Unidad de Energía Renovable por las facilidades otorgadas para realizar este trabajo.

A la Facultad de Ingeniería de la Universidad Autónoma de Yucatán.

A mis padres William V. Rubio Kú y Landy E. de G. Cámara Ramírez por haber hecho posible la llegada hasta esta línea de meta, estar siempre conmigo incondicionalmente y ser el motivo de superarme siempre.

A mis hermanos William A. Rubio Cámara y Stephany A. Rubio Cámara por su apoyo y cariño incondicional.

A mi compañera, por su persistente paciencia, comprensión, apoyo durante esta nueva etapa.

Al Dr. Luis Carlos Ordóñez López, por darme la oportunidad de trabajar en este proyecto, por su importante colaboración y ayuda para la realización de esta tesis.

Al Dr. Luis J. Ricalde Castellanos por su dedicación, tiempo, paciencia para alimentar generosamente de conocimientos a este trabajo.

Al Dr. Víctor M. Ramírez Rivera y Dr. Bassam Ali, por las sugerencias y críticas que ayudaron a enriquecer este trabajo.

A los profesores M. C. Lifter Ricalde, Tec. Sergio Canché, M. C. Ernesto Ordoñez del departamento de Energías Renovables en la Facultad de Ingeniería de la UADY, por su dedicación, tiempo, paciencia para alimentar generosamente de conocimientos a este trabajo, por su importante colaboración y ayuda para la realización de esta tesis.

A mis compañeros de generación, a todos gracias por su amistad.

ÍNDICE

NOMENCLATURA.....	vi
LISTADO DE TABLAS.....	ix
LISTADO DE FIGURAS.....	x
RESUMEN.....	xii
ABSTRACT	xiii
INTRODUCCIÓN.....	1
JUSTIFICACIÓN.....	2
CAPÍTULO 1 ANTECEDENTES	4
1.1.-Estudio del estado del arte	4
1.2.-Redes eléctricas inteligentes	13
1.3.-Sistemas fotovoltaicos.....	14
1.3.1.-Potencial solar	15
1.3.2.-Tecnologías de celdas fotovoltaicas	15
1.3.2.1.-Paneles fotovoltaicos monocristalinos	16
1.3.2.2.-Paneles fotovoltaicos policristalinos.....	19
1.4 Celdas de Hidrógeno... ..	19
1.5.-Redes neuronales artificiales.....	19
1.6.-Topologías de microred eléctrica inteligente.....	20
1.6.1.-Sistema Híbrido de Generación Eléctrica (SHGE)... ..	21
1.6.2.-Topologías en serie.	22
1.6.3.-Topología paralelo con acoplamiento en CD.	23
1.7.-Hipótesis.....	24
1.8.-Objetivos... ..	24
CAPÍTULO 2 METODOLOGÍA	25
2.1.- Modelo matemático del sistema fotovoltaico.....	25
2.1.1.-Curvas de potencia de los módulos fotovoltaicos.....	27

2.2.- Modelos dinámicos de la celda de combustible.	29
2.2.1- Modelo semi-empírico de la celda de combustible.....	30
2.2.2- Modelo dinámico de celda de combustible para integración a la microred.	31
2.2.2.1 Difusión de gas en los electrodos.....	32
2.2.2.2.- Voltaje de salida de la celda de combustible.....	35
2.2.2.3.- Caídas de voltaje en la celda.	36
2.2.3.- Ecuaciones termodinámicas.	38
2.3.- Modelo de circuito eléctrico equivalente supercapacitores basado en redistribución de cargas por difusión..	44
2.4.- Modelo dinámico del electrolizador alcalino.....	48
2.4.1- Modelo electroquímico.....	49
2.4.2- Modelo térmico del electrolizador.....	50
2.5.-Generación de potencia para la instalación fotovoltaica.	54
2.6.-Dimensionamiento de la planta fotovoltaica en la red eléctrica inteligente.....	55
2.7.-Dimensionamiento del electrolizador y celda de combustible.	60
2.8.- Aproximación de funciones mediante redes neuronales de alto orden.	61
2.8.1.-Entrenamiento por el Filtro Extendido de Kalman.	65
2.8.2.- Estructura del vector regresor de la red neuronal.....	66
2.9.- Gestión energética de la microred eléctrica inteligente.	68
2.9.1.- Descripción del problema de gestión energética.....	68
2.9.2.- Redes neuronales dinámicas para programación lineal.	71
2.10.- Metodología de integración de la microred.	72
CAPÍTULO 3 RESULTADOS.....	74
3.1.-Caracterización de las curvas de potencia de los paneles fotovoltaicos y celda de combustible utilizando redes neuronales de alto orden.....	74
3.2.-Predicción de la generación fotovoltaica.....	77
3.3.-Operación del sistema de gestión de cargas energéticas	83
CONCLUSIONES	92
REFERENCIAS	95
ANEXOS.....	9

NOMENCLATURA

A	Área del electrodo, m^2
A_r	Área del barrido, m^2
C_{cw}	Capacidad térmica del anticongelante
C_{elec}	Capacidad de refrigeración en el electrolizador, $J^\circ C^{-1}$
C_p	Coefficiente de potencia del rotor
C_t	Capacidad térmica del electrolizador, JK^{-1}
emf	Fuerza electromotriz, v
F	Constante de Faraday, $96,485 \text{ kJ} (kmol)^{-1}$
f_1, f_2	Parámetros de eficiencia de Faraday
G	Energía libre de Gibbs de formación $kJ (kmol)^{-1}$
h_{cond}	Parámetro relacionado con la transferencia de calor por conducción, $W K^{-1}$
h_{conv}	Parámetro relacionado con la transferencia de calor por convección, $W K^{-1}$
I	Corriente de carga, A
I_L	Corriente fotovoltaica, A
I_o	Corriente de saturación, A
LMTD	Diferencia media logarítmica de temperatura $^\circ C$
M_{H_2}	Masa molar de hidrógeno, $kg mol^{-1}$
N_{H_2}	Flujo másico molar de hidrogeno, $k mol s^{-1}$

n_c	Numero de celdas
P_b	Presión del tanque de almacenamiento, Pa
P_{bi}	Presión inicial del tanque de almacenamiento, Pa
R_g	Constante del gas ideal, $8.3144621, J(molK)^{-1}$
R_s	Resistencia en serie,
R_t	Resistencia térmica general del electrolito
R_{ohm}	Resistencia óhmica,
r	parámetro relacionado con la resistencia óhmica del electrolito, Ωm^2
s	Factor de sobrepotencial, v
T	Temperatura, $^{\circ}C$
T_b	Temperatura en operación, $^{\circ}C$
T_F	Fricción de Coulomb, $mPa s$
UA_{HX}	Coefficiente global de transferencia de calor, $W^{-1}K$
v	Voltaje, v
V_{act}	Voltaje de activación, v
V_{cell}	Voltaje total, v
V_{ohm}	Voltaje óhmico, v
V_{rev}	Voltaje reversible, v
V_b	Volumen del tanque de almacenamiento, m^3
z	Número de electrones,

z_s	Factor de compresión del sistema.
y_F	Eficiencia de Faraday, %
ΔG	Cambio en la energía de Gibbs
ΔH	Cambio en la entalpía, $Jmol^{-1}$
ΔS	Cambio en la entropía $JK^{-1}mol^{-1}$
\dot{n}	Rango del flujo molar, mol / s
\dot{Q}	Rango de transferencia de calor, w
Δt	Intervalo de tiempo, s

LISTADO DE TABLAS

Tabla 1.1.-Tabla de eficiencia de elementos en instalaciones fotovoltaicas.....	19
Tabla 1.2.-Modelo matemático de potencia de inversor para conexión a red	20
Tabla 1.3.-Modelo matemático de corriente-voltaje en celdas solares.....	21
Tabla 1.4.-Tabla de eficiencias de celdas solares	30
Tabla 2.1.-Parámetros de simulación de una curva I-V y curva de potencia para el módulo S60MC	41
Tabla 2.2.-Los parámetros del modelo para el módulo de potencia BPS Nexa	44
Tabla 2.3.-Parámetros del modelo eléctrico equivalente del Stack SR-12 PEMFC.....	57
Tabla 2.4.- Parámetros de curva I-V de electrolizador	66
Tabla 2.5.- Parámetros de eficiencia de Faraday	66
Tabla 2.6.- Parámetros UAHX	66
Tabla 2.7.-Irradiación promedio diaria para la ciudad de Mérida	69
Tabla 3.1.-Costo de operación de la microred	99

LISTADO DE FIGURAS

Figura 1.1.- Sistema híbrido fotovoltaico / celda de combustible de Tischer y Verbic. ...	18
Figura 1.2.- Diagrama de bloques del flujo de energía en una casa inteligente.	19
Figura 1.3.-Sistema de respaldo Jupiter de FutureE.....	22
Figura 1.4.- Modelo de Hopfield de una neurona.....	24
Figura 1.5.-Panel monocristalino(a) y panel policristalino (b)	29
Figura 1.6.-Eficiencias de conversión de los distintos tipos de celdas solares.....	31
Figura 1.7.-Representación esquemática de una red neuronal.....	33
Figura 1.8.-Diagrama a bloques de un SHGE	34
Figura 1.9.-Topología serie del SHGE	35
Figura 1.10.-Topología en paralelo del SHGE	36
Figura 2.1.-Curvas I-V del panel fotovoltaico S60MC	40
Figura 2.2.- Diagrama en Simulink para obtención de corriente y voltaje de un panel fotovoltaico	41
Figura 2.3.-Curva I-V y Curva de potencia a 25° C para diferentes rangos de irradiancia en un panel de S60MC.	42
Figura 2.4.- Curva de voltaje contra corriente para modelo semi-empírico	44
Figura 2.5.- Circuito equivalente del efecto de carga de doble capa.....	51
Figura 2.6.- Diagrama de bloques para circuito eléctrico equivalente en una celda de combustible.....	53
Figura 2.7.-Diagrama en Simulink para obtención de corriente y voltaje de un panel fotovoltaico	53
Figura 2.8.-Circuito equivalente para pérdidas de voltaje de activación	54
Figura 2.9.-Circuito equivalente para las pérdidas de voltaje óhmicas.....	55
Figura 2.10.-Circuito eléctrico equivalente para caídas de voltaje de concentración ...	55
Figura 2.11.- Circuito equivalente para modelar propiedades termodinámicas.....	56
Figura 2.12.- Circuito eléctrico equivalente del supercapacitor.....	58
Figura 2.13.-Circuito eléctrico equivalente con dos ramas RC del supercapacitor.....	60
Figura 2.14.-Curva de Potencia para supercapacitor de 10 F y 2.7 V	61
Figura 2.15.-Flujo volumétrico producido por el electrolizador	67
Figura 2.16.-Sistema de generación de energía fotovoltaica de 22 kW	68
Figura 2.17.-Curvas de irradiación diaria para la ciudad de Mérida (año 2013)	69
Figura 2.18.-Potencia de la carga para un mes con muestras cada 5 minutos.	70
Figura 2.19.-Potencia fotovoltaica generada para mes de abril en una instalación de 7 kW.....	71
Figura 2.20.-Potencia fotovoltaica generada para mes de febrero en una instalación de 7 kW.....	73
Figura 2.21.-Modelo en Simulink de electrolizador de 26 kW	74
Figure 2.22.-Estructura de Red alto orden.	75
Figura 2.23.-Esquema del prototipo del SHGE a analizar.....	83

Figura 3.1.-Aproximación de Curva I-V a 25° mediante red neuronal para diferentes niveles de irradiancia.....	87
Figura 3.2.- Aproximación de Curva de Potencia a 25°C mediante red neuronal para diferentes niveles de irradiancia.	88
Figura 3.3.- Medida de desempeño de la red neuronal para aproximación de la curva I-V.....	89
Figura 3.4.- Medida de desempeño de la red neuronal para aproximación de la curva de potencia	89
Figura 3.5.-Generación de potencia para 15 días de planta de 22 kW	90
Figura 3.6.-Cálculo de la dimensión utilizando el método de Cao.	91
Figura 3.7.-Aproximación de la generación fotovoltaica usando redes neuronales.....	92
Figura 3.8.-Predicción de la generación fotovoltaica para 24 horas.....	93
Figura 3.9.-Predicción de la demanda energética.....	94
Figura 3.10.-Potencia entregada al electrolizador y potencia a demandar de la celda de combustible	95
Figura 3.11.-Eficiencia de Faraday del electrolizador y flujo de Hidrógeno.....	96
Figura 3.12.- Flujo de potencia en la microrred con sistema de gestión	101
Figura 3.13.-Masa de hidrógeno en el tanque de almacenamiento	101
Figura 3.14.-Demanda eléctrica contra producción por energía renovable.	102
Figura 3.15.-Evolución de las variables de decisión.	103
Figura 3.16.-Costo de operación de la microrred.....	103

RESUMEN

En este trabajo de tesis se utilizan herramientas de inteligencia computacional para la operación de una red eléctrica inteligente. En particular se aplican redes neuronales artificiales para: estimar las curvas voltaje-corriente y voltaje-potencia en módulos fotovoltaicos, predicción de la generación de potencia de instalaciones fotovoltaicas, demanda de edificios y obtener la solución de un problema de programación lineal para la gestión de cargas y generación de energía en una microred.

Se obtuvieron los modelos matemáticos de cada fuente de energía que participa en una microred eléctrica compuesta de un arreglo de paneles fotovoltaicos, un electrolizador, una celda de combustible y un banco de capacitores. Los resultados fueron validados utilizando mediciones reales y simulaciones de modelos comerciales ya reportados en la literatura.

Los resultados de este trabajo podrán extenderse para incluir diferentes tipos de fuentes de energía ya sean renovables o convencionales, además de poder considerar costos dinámicos.

ABSTRACT

In this thesis, computational intelligence tools are employed in order to operate a smart grid. In particular, artificial neural networks are applied for: estimation of the voltage-current and voltage-power curves in photovoltaic modules, forecasting for power generation in photovoltaic arrays, building's electrical load and solution of a linear programming problem for smart grids energy generation and load management.

Mathematical models were obtained for each energy source that participates in the smart grid which is composed of a photovoltaic array, an electrolyser, a fuel cell and supercondenser bank. Results were validated using experimental measurements and simulations of commercial devices reported in literature.

The results of this work can be extended to include several types of energy sources, renewables or conventional, and also of being able to consider dynamic pricing.

INTRODUCCIÓN

La península de Yucatán es considerada como la tercera región más rica del país en términos del potencial eólico y solar [1]. Se estima una potencia eólica de 1000 MW y la irradiación solar se encuentra alrededor de 6 kWh/m². Este gran potencial ha captado la atención de corporativos públicos y privados con el propósito de establecer plantas de generación de gran escala.

Actualmente vivimos una crisis de energía debido a la creciente demanda mundial, encareciéndose la explotación de los combustibles derivados del petróleo; al generar energía con los combustibles fósiles, se emiten gases de efecto invernadero, causantes del calentamiento global, la alteración del clima y el hábitat.

Los costos de producción y almacenamiento de diversas fuentes de energía renovables de baja capacidad han disminuido. En los últimos años el costo del kW instalado de energía fotovoltaica se ha reducido entre 2000 a 4000 dólares, siendo las reducciones de energía más bajas. Seguido de la energía eólica con un costo 3000 a 8000 dólares por kW instalado [2]. Actualmente hay muchos trabajos sobre la integración de las energías renovables a redes eléctricas públicas como consecuencias de esta reducción de costos [3-5]. Los primeros pasos en la integración de fuentes de energía renovable se dieron con la implementación de sistemas híbridos fotovoltaicos/eólicos como fuentes complementarias para aplicaciones rurales y conexiones débiles a la red, donde el nivel de voltaje no siempre se puede mantener constante [6]. Actualmente se realiza investigación en la integración de diversas fuentes de energía de pequeña escala tales como solar térmica, biomasa, celdas de combustible y mareomotriz en instalaciones menores a los 100 kW. Esta integración se realiza bajo nuevos y avanzados esquemas de control constituyendo lo que se denomina una red eléctrica inteligente.

JUSTIFICACIÓN

A pesar de la extensión de la red eléctrica lograda en el último siglo, actualmente gran parte de la población del mundo vive todavía sin una fuente de energía eléctrica. Más de mil millones de personas en países en vías de desarrollo no cuentan con un suministro de electricidad o éste no satisface sus requerimientos.

La demanda de la red eléctrica inteligente en general no coincide en el tiempo con la generación de fuentes renovables, la microred requiere de dispositivos de almacenamiento de energía. Con el desarrollo de tecnologías de hidrógeno, el almacenamiento de la energía en forma de hidrógeno es una opción muy prometedora con menor impacto ambiental. Sin embargo, los costos actuales de los componentes (electrolizador, tanque de almacenamiento de hidrógeno y celdas de combustible) son altos. Un esquema de almacenamiento de energía basado en la tecnología de hidrógeno gas puede implementarse en el diseño de microrredes para garantizar la sustentabilidad energética de un edificio.

En este trabajo de tesis, se propone diseñar una microred eléctrica compuesta por sistemas de generación fotovoltaica, celda de combustible y una fuente de respaldo basado en un capacitor. Todos estos dispositivos estarán integrados en un bus de corriente directa (DC). Las variables de radiación solar se caracterizan con los datos experimentales de una estación meteorológica y la generación fotovoltaica. La celda de combustible es dimensionada de acuerdo a la demanda de energía del edificio de Mecatrónica en la Facultad de Ingeniería de la UADY (Universidad Autónoma de Yucatán). Con el fin de garantizar la sustentabilidad energética del edificio, se diseñará un sistema de gestión basado en una red neuronal artificial con el fin de procesar la información de las mediciones de generación, demanda energética y toma de decisiones sobre qué carga alimentar en el interior del edificio. La base de conocimientos del sistema utiliza los modelos matemáticos de los elementos de generación, las predicciones de generación de energía y demanda de carga mediante redes neuronales que serán entrenadas con un algoritmo basado en el filtro de Kalman (EKF) [6]. El entrenamiento por EKF de las redes neuronales, tanto estáticas y las recurrentes, ha demostrado ser fiable para muchas aplicaciones en los últimos diez años debido a que se mejora la velocidad de convergencia en el aprendizaje y es robusto en presencia de ruido en la medición. La

gestión energética se realiza a partir de un algoritmo de optimización de una función objetivo y un conjunto de restricciones, basado en redes neuronales dinámicas diseñadas específicamente para resolver problemas de programación lineal, donde las ecuaciones de restricciones y función objetivo son lineales [7].

CAPÍTULO 1

ANTECEDENTES

1.1 Estudio del estado del arte

Una microred eléctrica inteligente debe garantizar la sustentabilidad energética de una edificación principalmente a partir de la generación fotovoltaica. En las situaciones donde la generación de electricidad en el sistema fotovoltaico exceda la demanda del edificio, la energía excedente podría ser almacenada en forma de hidrógeno en hidruros metálicos y, emplearla posteriormente, mediante una celda de combustible cuando sea necesaria.

En el trabajo de Hidaka [3], se presenta el modelado y una estrategia de operación de un sistema híbrido fotovoltaico y celda de combustible como se muestra en la figura 1.1. El comportamiento del sistema completo es evaluado mediante simulación por un periodo de 24 hrs. En el trabajo de Tischer and Verbic [8] estudiaron un sistema de gestión de energía para una casa inteligente. Dicha casa fue equipada con una celda de combustible, la cual se utilizó para la cogeneración de potencia y almacenamiento térmico, un sistema fotovoltaico, un carro eléctrico y una unidad de almacenamiento de energía térmica. Se empleó el método de optimización nominado programación dinámica, donde cada variable de decisión perteneciente a la función objetivo es analizada en una etapa distinta a partir de sus variables de estado, que consideró las consecuencias financieras de la demanda energética, la generación, y la disponibilidad de energía para la carga de las baterías del carro eléctrico de acuerdo con las preferencias y hábitos del conductor del carro eléctrico. Se evaluó el desempeño y se comparó con un sistema de gestión más simple con la intención de generar la mayor cantidad de energía posible dentro de la casa. Se encontró que el sistema responde adecuadamente a la demanda y generación eléctrica en la casa ante una tarifa eléctrica variable. La Fig. 1.2 muestra el diagrama de bloques del flujo energético en la casa inteligente. Los resultados de la investigación de Tischer y Verbic [8], incluyen las curvas de la operación del sistema de gestión energética para un periodo de 24 horas donde se muestran las funciones de eficiencia de descarga de la batería, eléctrica y térmica de la celda de combustible y de conversión del inversor todas en función de la energía consumida (kWh); los valores

medio y desviaciones estándar para la demanda eléctrica, la demanda térmica y la generación fotovoltaica para k muestras en un periodo de 24 horas donde se toman muestras cada 15 minutos.

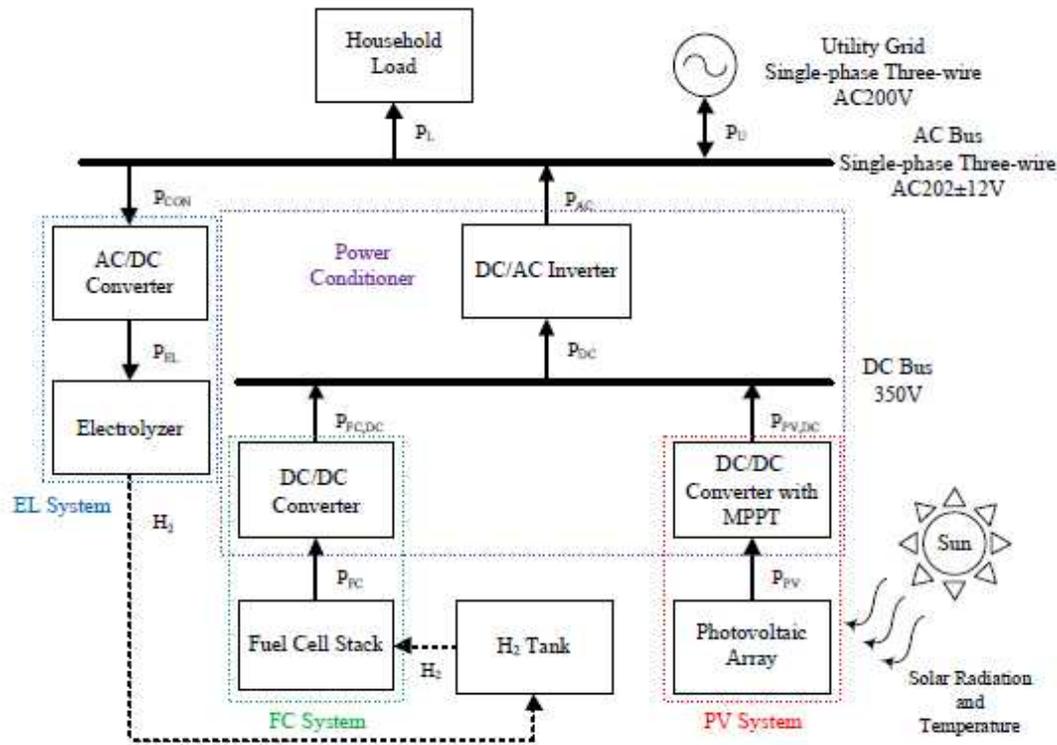


Figura 1.1.- Sistema híbrido fotovoltaico / celda de combustible de Hidaka [3]

Ishida, [9], propuso un sistema que integra diversas fuentes de energía renovable y la red de distribución eléctrica convencional, con la intención de realizar una distribución inteligente basada en el intercambio de excesos y carencias de energía en un conjunto de hogares a partir de modelos de reproducción biológicos. Las fuentes de energía involucradas fueron: paneles fotovoltaicos, celdas de combustible y colectores solares.

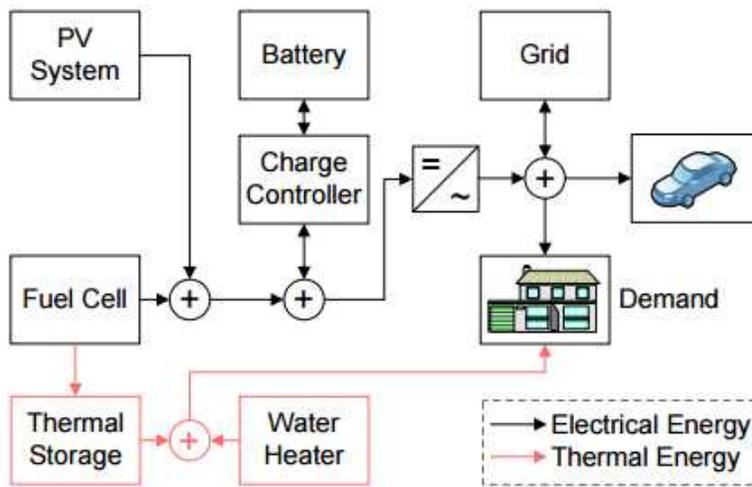


Figura 1.2.- Diagrama de bloques del flujo de energía en una casa inteligente [8]

Un sistema fotovoltaico básico incluye paneles fotovoltaicos, líneas de cableado, un inversor y dispositivos de almacenamiento eléctrico. En general, el sistema incluye un sistema de monitoreo para registrar los datos ambientales y el rendimiento del sistema. Con el fin de predecir la generación de energía a partir de una serie de módulos fotovoltaicos, en los trabajos de Marion y King, [10-11], se propusieron el uso de modelos matemáticos para caracterizar sistemas de generación que constan de módulos fotovoltaicos e inversores de conexión a red donde se usan parámetros típicos del sistema para estimar el rendimiento. En el trabajo de Marion [10], se estiman los parámetros de desempeño de un sistema fotovoltaico conectado a la red en función de los parámetros de pérdidas de cada elemento de la generación de potencia de cada elemento de la instalación. La descripción de eficiencia del sistema a partir de parámetros de desempeño se muestra en la Tabla 1.1, donde se considera tanto la fuente como las pérdidas a través de conexiones de los elementos del sistema.

Tabla 1.1.- Tabla de eficiencia de elementos en instalaciones fotovoltaicas [10]

Elementos	Valor típico	Rango
Potencia nominal del módulo	1.00	0.85-1.05
Degradación inducida por luz	0.98	0.90-0.99
Cableado DC	0.98	0.97-0.99
Diodos y conexiones	0.995	0.99-0.997
Desajuste	0.98	0.97-0.995
Inversor	0.96	0.93-0.97
Transformador	0.97	0.96-0.99

Cableado AC	0.99	0.98-0.993
Suciedad	0.95	0.75-0.995
Sombreado	1.00	0.0-1.00
Seguimiento del sol	1.00	0.98-1.00
Disponibilidad del sistema	0.98	0.0-0.995
Eficiencia general en condiciones estándar	0.804	0.62*-0.964
Eficiencia por temperatura (Factor de pérdida de potencia=-45%/°C)	0.91	
Eficiencia general en temperatura de operación de celda	0.731	

* No incluye suciedad, el sombreado, el seguimiento, la disponibilidad o pérdidas.

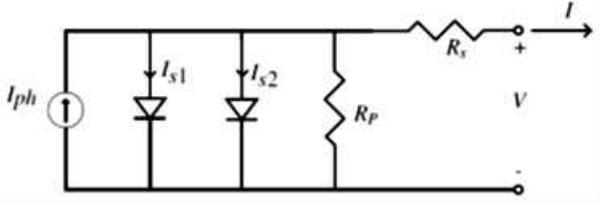
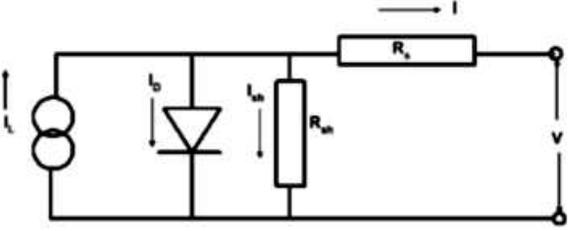
En [11], se presenta un modelo de generación de potencia fotovoltaica, desarrollado a partir del desempeño del inversor de conexión a red. El modelo, mostrado en la Tabla 1.2, fue validado a partir de mediciones de inversores de uso comercial y residencial.

Tabla 1.2.- Modelo matemático de potencia de inversor para conexión a red [11]

Modelo matemático	Parámetros
$P_{ac} = \left(\frac{P_{aco}}{(A-B)} - C(A-B) \right) (P_{dc} - B) + C(P_{dc} - B)^2$ <p>donde</p> $A = P_{dco} (1 + C_1(V_{dc} - V_{dco}))$ $B = P_{so} (1 + C_2(V_{dc} - V_{dco}))$ $C = C_0 (1 + C_3(V_{dc} - V_{dco}))$	<p>P_{ac} : Potencia de salida AC del inversor basado en la potencia de entrada y el voltaje</p> <p>P_{dc} : Potencia de entrada DC al inversor</p> <p>V_d : Voltaje de entrada DC</p> <p>P_{aco} : Máxima potencia de corriente alterna para el inversor en condición de operación nominal</p> <p>P_{dco} : Potencia DC en que se alcanza la potencia AC en la condición de operación de referencia.</p> <p>V_{dco} = Voltaje DC en que se alcanza la potencia AC en la condición de operación de referencia.</p> <p>P_{so} = Potencia DC necesaria para iniciar el inversor</p> <p>C_0 = parámetro de curvatura de la relación entre la potencia AC y DC</p> <p>C_1 = Coeficiente empírico para P_{dco}</p> <p>C_2 = Coeficiente empírico para P_{so}</p> <p>C_3 = Coeficiente empírico de variación lineal de C_0 con la entrada de voltaje de corriente,</p>

Goetzberger [12] desarrolla un modelo del módulo fotovoltaico que puede ser expresado por circuitos eléctricos equivalentes de doble diodo donde los parámetros del circuito se pueden obtener a partir de experimentación con irradiación y temperaturas controladas. El modelo presentado por Goetzberger [12] es uno de los más utilizados para obtener la curva corriente-voltaje de una celda fotovoltaica; el modelo de doble diodo se presenta en la Tabla 1.3. Otros modelos utilizan datos de las hojas de especificaciones, (corriente de corto, voltaje de circuito abierto, resistencia de derivación, corriente y voltaje de máxima potencia) en condiciones controladas para estimar los parámetros del módulo en condiciones de operación diferentes [13]. Los modelos más complejos requieren parámetros específicos que relacionan los niveles de voltaje entre las líneas de DC del panel y AC para integración a red y que se obtienen a través de rigurosas pruebas de los componentes de los sistemas fotovoltaicos [11].

Tabla 1.3.-Modelo matemático de corriente-voltaje en celdas solares [12-13]

Circuito eléctrico	Modelo dinámico Corriente I –Voltaje V de celda fotovoltaica
	<p>Modelo de doble diodo [12];</p> $I - I_{ph} + I_{S1} \left[\exp \left(\frac{V + IR_s}{n_1 V_T} \right) - 1 \right] + I_{S2} \left[\exp \left(\frac{V + IR_s}{n_2 V_T} \right) - 1 \right] + \frac{V + IR_s}{R_p} = 0$ <p>I_{ph}: fotocorriente I_{S1}, I_{S2}: corrientes de saturación de diodo n_1, n_2: factores de diodo ideal R_s: resistencia en serie R_p: resistencia en paralelo V_T: voltaje térmico a una temperatura T</p>
	<p>Modelo de 5 parámetros [13],</p> $I = I_L - I_0 \left[\exp \left(\frac{V + IR_s}{a} \right) - 1 \right] + \frac{V + IR_s}{R_p}$

Por otra parte, la tecnología del hidrógeno está alcanzando su madurez dentro de los esquemas de generación con fuentes renovables. Las celdas de combustible tienen un mejor desempeño en un mayor intervalo de temperaturas de operación en comparación con las baterías; las cuales pierden eficiencia en bajas temperaturas y a altas temperaturas acortan su vida útil. Además, el tiempo de respuesta de la celda de combustible ante la desconexión es más rápido, debido a que la energía necesaria para activarlas es poca lo cual acorta el periodo de transición ante una pérdida de potencia [4]. Las celdas de combustible requieren menor mantenimiento en comparación con un generador diésel y su impacto ambiental es mucho menor en comparación con las emisiones de gases de los generadores diésel.

Osswald [4], presenta el diseño de un sistema de generación escalable para aplicaciones de respaldo en sistemas no conectados a la red y con una potencia máxima de 50 kW con eficiencia superior al 50%. Este sistema integra un electrolizador, una celda de combustible, un sistema de almacenamiento de agua y otro para el almacenamiento de hidrógeno. El electrolizador opera con energía obtenida de un sistema fotovoltaico, eólico o directamente de la red. El sistema de generación utiliza un controlador para ajustarse al voltaje de entrada con opción de integrarse a una red eléctrica inteligente. Este sistema ha sido ya implementado a gran escala en empresas alemanas de telecomunicaciones.

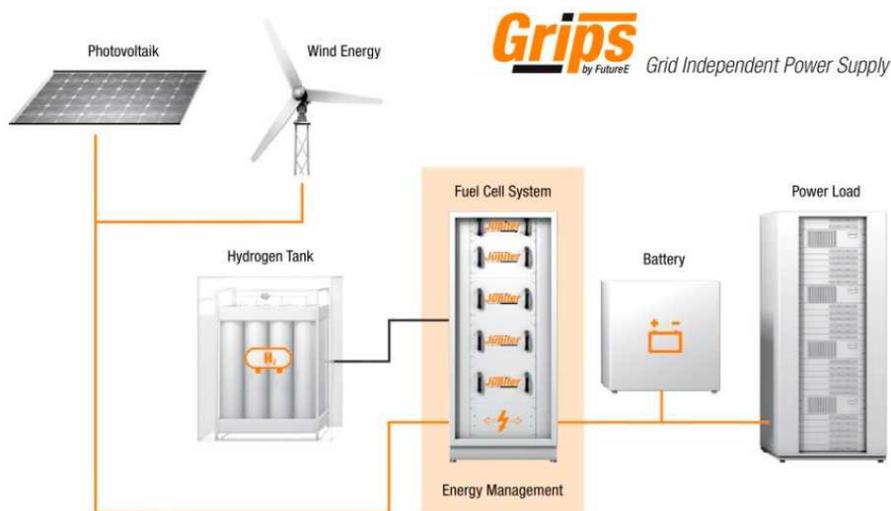


Figura 1.3.- Sistema de respaldo Jupiter de FutureE

En la figura 1.3, se presenta el diseño del prototipo de micro red diseñado en [4] donde se integra 4 MW de energía eólica, 4 MW de energía fotovoltaica, electrolizador de 10 MW, y vehículos eléctricos con celda de combustible para alimentar una industria ubicada en una isla considerando vehículos terrestres y marinos impulsados por hidrógeno. El sistema puede tomar hasta 5 MW de la red pública de ser necesario. Osswald desarrolló en [4] un modelo matemático de los sistemas de generación y una simulación de Montecarlo para la demanda por parte de los usuarios. El modelo de simulación consideró el desempeño del sistema de energía por hidrógeno ante dos diferentes escenarios: verano e invierno, de donde toma como entrada al modelo las condiciones ambientales de velocidad de viento y radiación solar. A partir de sus resultados en simulación de la potencia disponible para generación de hidrógeno se obtuvo una estimación del número de vehículos que se pueden atender en función de las condiciones ambientales.

Las redes neuronales artificiales se han aplicado de forma exitosa en problemas como el control de sistemas, clasificación de patrones, reconocimiento de patrones, predicción de series de tiempo y solución de problemas de optimización [14]. Las redes neuronales artificiales son atractivas debido a su fácil implementación, estructura relativamente simple, robustez y la capacidad de ajustar sus parámetros en línea [15]. Recientemente, se están aplicando las herramientas de inteligencia computacional en el campo de las energías renovables en problemas de: modelado dinámico, control y predicción. En [16] aplican las redes neuronales artificiales para estimar el ajuste dinámico de precios de energía eléctrica, generando un modelo de respuesta a la demanda de los consumidores a los cambios en precios. Utilizando un algoritmo de optimización se puede identificar el ajuste dinámico de precios óptimo para inducir la respuesta deseada con respecto a una función objetivo predefinida y las restricciones dadas por los consumidores. El ajuste dinámico de precios y los métodos de predicción ayudan a una mejor gestión de los recursos energéticos y reducción de costos de electricidad.

Las redes recurrentes están basadas en el modelo de Hopfield y son consideradas como buenas candidatas para aplicaciones como reconocimiento de patrones, análisis de series de tiempo, procesamiento de señales y control debido a su principal propiedad que es la de generar un aprendizaje a partir de una serie de datos de entrada [17]. La red de Hopfield está definida a partir de una analogía eléctrica del comportamiento biológico de

una neurona. Cada neurona de la red de Hopfield tiene su salida retroalimentada a través de un elemento de retardo unitario hacia otras neuronas de la red.

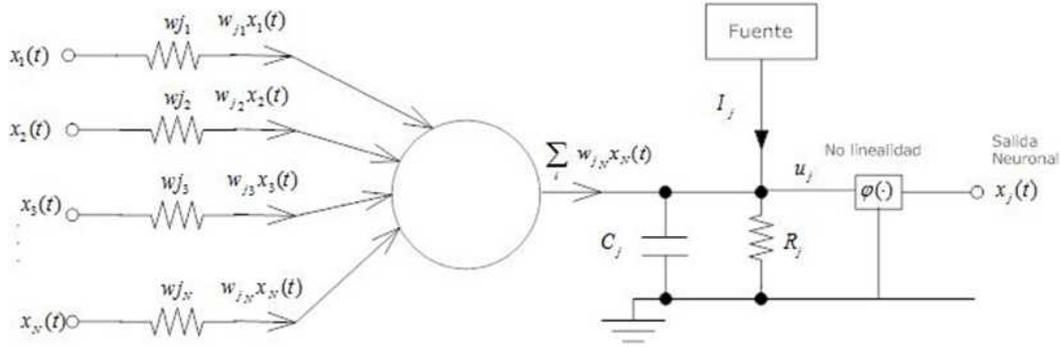


Figura 1.4. Modelo de Hopfield de una neurona

El modelo de una red de Hopfield se muestra en la Figura 1.4, donde para cada neurona j , u_j se denomina voltaje de activación, x_j es el voltaje de salida de la neurona, C_j es la capacitancia de la membrana, R_j es la resistencia de la membrana e I_j es la corriente de entrada. Esta estructura permite que todas las neuronas se puedan interconectar y que las conexiones sean positivas o negativas, con lo que se mejora la capacidad de procesamiento al tener un mayor número de parámetros a adaptar en el proceso de aprendizaje.

De la Figura 1.4, por la ley de corrientes de Kirchhoff en el nodo de entrada de la función no lineal, se tiene

$$C_j \frac{du_j(t)}{dt} + \frac{u_j(t)}{R_j} = \sum_{i=1}^N w_{ji} x_i(t) + I_j$$

donde el término de capacitancia $C_j \frac{du_j(t)}{dt}$ es la manera de introducir un término dinámico que represente la memoria de la neurona.

Finalmente, la salida de la neurona j , está dada por

$$x_j(t) = \varphi(u_j(t))$$

La estructura dinámica presentada es comúnmente referida como el modelo aditivo y constituye la base de la neurodinámica [17].

Para un sistema de N neuronas, la red neuronal queda definida como

$$C_j \frac{du_j(t)}{dt} = -\frac{u_j(t)}{R_j} + \sum_{i=1}^N w_{ji} x_i(t) + I_j, \quad j = 1, \dots, N$$

donde la función de activación de la neurona se define como

$$\varphi(u_j) = \frac{1}{1 + \exp(-u_j)}$$

Por otra parte, el problema de diseñar un sistema eficiente para la gestión de energía ha atraído recientemente el interés de investigadores en el área de inteligencia computacional. Gran parte de los problemas abiertos en redes eléctricas inteligentes está enfocado al diseño de sistemas de gestión energética. Battistelli [18], propone el algoritmo flujo de potencia óptimo distribuido y en paralelo (DPOPF), el cual se aplica para resolver problemas de flujo de potencia óptimo (OPF) en un sistema de transmisión de red inteligente con fuentes de energía renovables, en un sistema de prueba de 26 autobuses. La energía de esta red es generada por fuentes de energía renovables, y justifica la exactitud de las soluciones obtenidas mediante simulaciones. En el trabajo de Battistelli [18], se presenta un análisis y sistematización del control de generación (AGC) de las redes de generación distribuida (DN), incluyendo vehículos eléctricos (EVs). Esta metodología diseña el servicio de AGC a nivel de distribución, y propone un modelo de optimización para evaluar el potencial de la prestación de AGC de vehículos eléctricos. El esquema está de acuerdo con un objetivo de la gestión económica óptima. Los resultados muestran que la metodología propuesta representa una herramienta flexible para que el operador utilice el sistema para la planificación operativa y la gestión de los servicios auxiliares tales como AGC con vehículos eléctricos.

1.2 Redes eléctricas inteligentes.

Una red eléctrica inteligente es un sistema interconectado de tecnologías de información y comunicación con tecnologías de generación, transmisión, distribución de electricidad y uso final que integra a su vez fuentes de energías renovables. Una red eléctrica inteligente integra tecnologías de información, instrumentación y control en generación, transmisión y distribución para lograr una distribución eficiente y económica de la electricidad. En una red eléctrica inteligente se presentan flujos bidireccionales de energía e información con lo que se tiene una participación activa del consumidor al autoabastecerse y cogenerar energía basada en información de los costos de la energía los cuales son variantes en el tiempo [19]. Una red eléctrica inteligente utiliza para su operación fuentes renovables de generación por parte de los grandes productores, micro-generación por parte de los consumidores y almacenamiento de energía, así como la integración de medios de transporte híbridos (eléctricos y de gasolina).

Con el objetivo de alcanzar las metas de las redes inteligentes, y así ayudar a mitigar la crisis de energía y el calentamiento global, los investigadores han realizado muchos esfuerzos para presentar nuevas teorías para constituir un sistema eléctrico de potencia seguro, económico y amigable con el medio ambiente [20].

Los principales beneficios que se persiguen al implementar una red eléctrica inteligente son:

- Mejorar la confiabilidad y calidad del suministro de la energía.
- Maximizar la generación de energía por parte de las fuentes ya instaladas y disminuir la construcción de plantas de respaldo.
- Incrementar la capacidad de generación y eficiencia de operación en las redes eléctricas existentes.
- Habilitar el mantenimiento predictivo y reducir los tiempos de recuperación ante disturbios en el sistema.
- Facilitar integración de las fuentes de energías renovables a la red eléctrica.
- Instalar fuentes de generación distribuida.

- Sistematizar el mantenimiento y la operación.
- Reducir las emisiones de gases de efecto invernadero al promover la participación de vehículos eléctricos y fuentes de energía renovable dentro de la red eléctrica.
- Reducir el consumo de combustibles fósiles al reducir la necesidad de generación innecesaria durante periodos de demanda pico.
- Permitir la participación de vehículos eléctricos conectados a la red y nuevos métodos de almacenamiento.
- Permitir e incentivar nuevos productos, servicios y mercados eléctricos con participación activa del consumidor.

Respecto a las fuentes de energía renovable en las redes eléctricas inteligentes, las instalaciones fotovoltaicas y eólicas se han convertido en la elección primaria de generación eléctrica, debido a que sus costos de instalación, operación, mantenimiento y remplazo se han reducido considerablemente, además de contar con una vida útil de alrededor de 25 años.

1.3.- Sistemas Fotovoltaicos.

Los dispositivos fotovoltaicos son la tecnología que convierte la radiación solar en electricidad y actualmente constituye el sector de mayor crecimiento en energías renovables. Las instalaciones fotovoltaicas se clasifican en dos tipos: sistemas autónomos y sistemas conectados a la red. Los sistemas fotovoltaicos autónomos son aquellos que se conectan directamente a la carga o a algún medio de almacenamiento y los sistemas conectados a la red utilizan un inversor y elementos de protección para conectarse a la red pública utilizando medidores de electricidad bidireccionales.

Los elementos que constituyen una instalación fotovoltaica son: panel fotovoltaico, baterías, elementos de acondicionamiento de potencia, estructuras y accesorios. Un panel fotovoltaico, compuesto de un arreglo de celdas solares en serie, está diseñado para captar parte de la radiación emitida por el sol y convertirla en energía eléctrica mediante el efecto fotovoltaico. Los módulos fotovoltaicos se pueden utilizar en conexión

con la red eléctrica, o bien en sitios aislados, por medio de sistemas que incluyen baterías.

1.3.1 Potencial Solar

La energía que llega a la tierra, proveniente del sol, resulta en una constante de energía solar en la tierra; $E_0 = 1367 \text{ W/m}^2$. Debido a las condiciones atmosféricas, la radiación de la luz solar puede presentarse en radiación directa (en la cual no existen elementos que se interpongan en el camino de la luz), radiación difusa (la cual se presenta cuando hay factores de interferencia, lo que permite el paso a solo una parte de la luz) y la reflexión (albedo). Es posible medir directamente la radiación solar usando sensores llamados piranómetros.

La medición de la radiación es útil en aplicaciones de control en la orientación de un sistema fotovoltaico, que podría ser automatizado para incrementar la generación eléctrica. Para esto, se estima la radiación solar de acuerdo a un método específico que puede ser: astronómico, a partir de datos estadísticos ó por un instrumento de medición. En todos estos casos se desea conocer la magnitud de la radiación y posición del sol para estimar el posicionamiento ideal del panel fotovoltaico usando un sistema automático.

1.3.2 Tecnologías de celdas fotovoltaicas

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.

Las celdas solares, en su gran mayoría, son producidas a partir del dióxido de silicio (SiO_2) y se clasifican, de acuerdo a su material constitutivo, en [21]:

Silicio monocristalino: de rendimiento energético entre 15% y 17 %;

Silicio policristalino: de rendimiento energético entre 12% y 14 %.

Silicio amorfo: con rendimiento energético menor del 10 %.

Otros materiales: arseniuro de galio, diseleniuro de indio y cobre, telurio de cadmio.

Suponiendo que la eficiencia de conversión de energía solar a eléctrica de un panel es del 15%, bastaría un área de 25 km² en el desierto de Sonora o Chihuahua para generar toda la energía eléctrica que requiere hoy en día el país, que fue de 244.6 TWh en 2014 [1] y [22]. La Tabla 1.4 sintetiza los datos de eficiencias de celdas solares de diferentes tipos de tecnologías. Comercialmente, la tecnología fotovoltaica más utilizada, debido a su eficiencia, es la de silicio monocristalino, seguida de las celdas policristalinas y las de silicio amorfo [23]. La Fig. 1.6 muestra la evolución histórica de las eficiencias de conversión energética de diversas tecnologías de celdas solares de acuerdo con datos del National Renewable Energy Laboratory (NREL) [24].

1.3.2.1.- Paneles fotovoltaicos monocristalinos

El silicio mono-cristalino es el material que presenta eficiencia y durabilidad superior a cualquier otro material utilizado en celdas solares. En laboratorio se han alcanzado rendimientos máximos del 24.7% para este tipo de celdas, mientras que en los modelos comerciales alcanzan eficiencias cercanas al 16% [21] y [23].



Figura 1.5.- Panel fotovoltaico monocristalino (a) y policristalino (b)

Tabla 1.4.-Tabla de eficiencias de celdas solares [23]

Tecnología fotovoltaica	Eficiencia en laboratorio	Eficiencia en módulo comercial
Silicio cristalino	12%-18%	15%-21%
Silicio amorfo	13%	5-8%
CIS (CuInSe ₂)	19.5%	5-11%
CdTe	16.5%	9%
GaAs (concentrada)	27%	
Dye-sensitized solar cell, DSSC	11%	5-7%
Celdas orgánicas	5.4%	

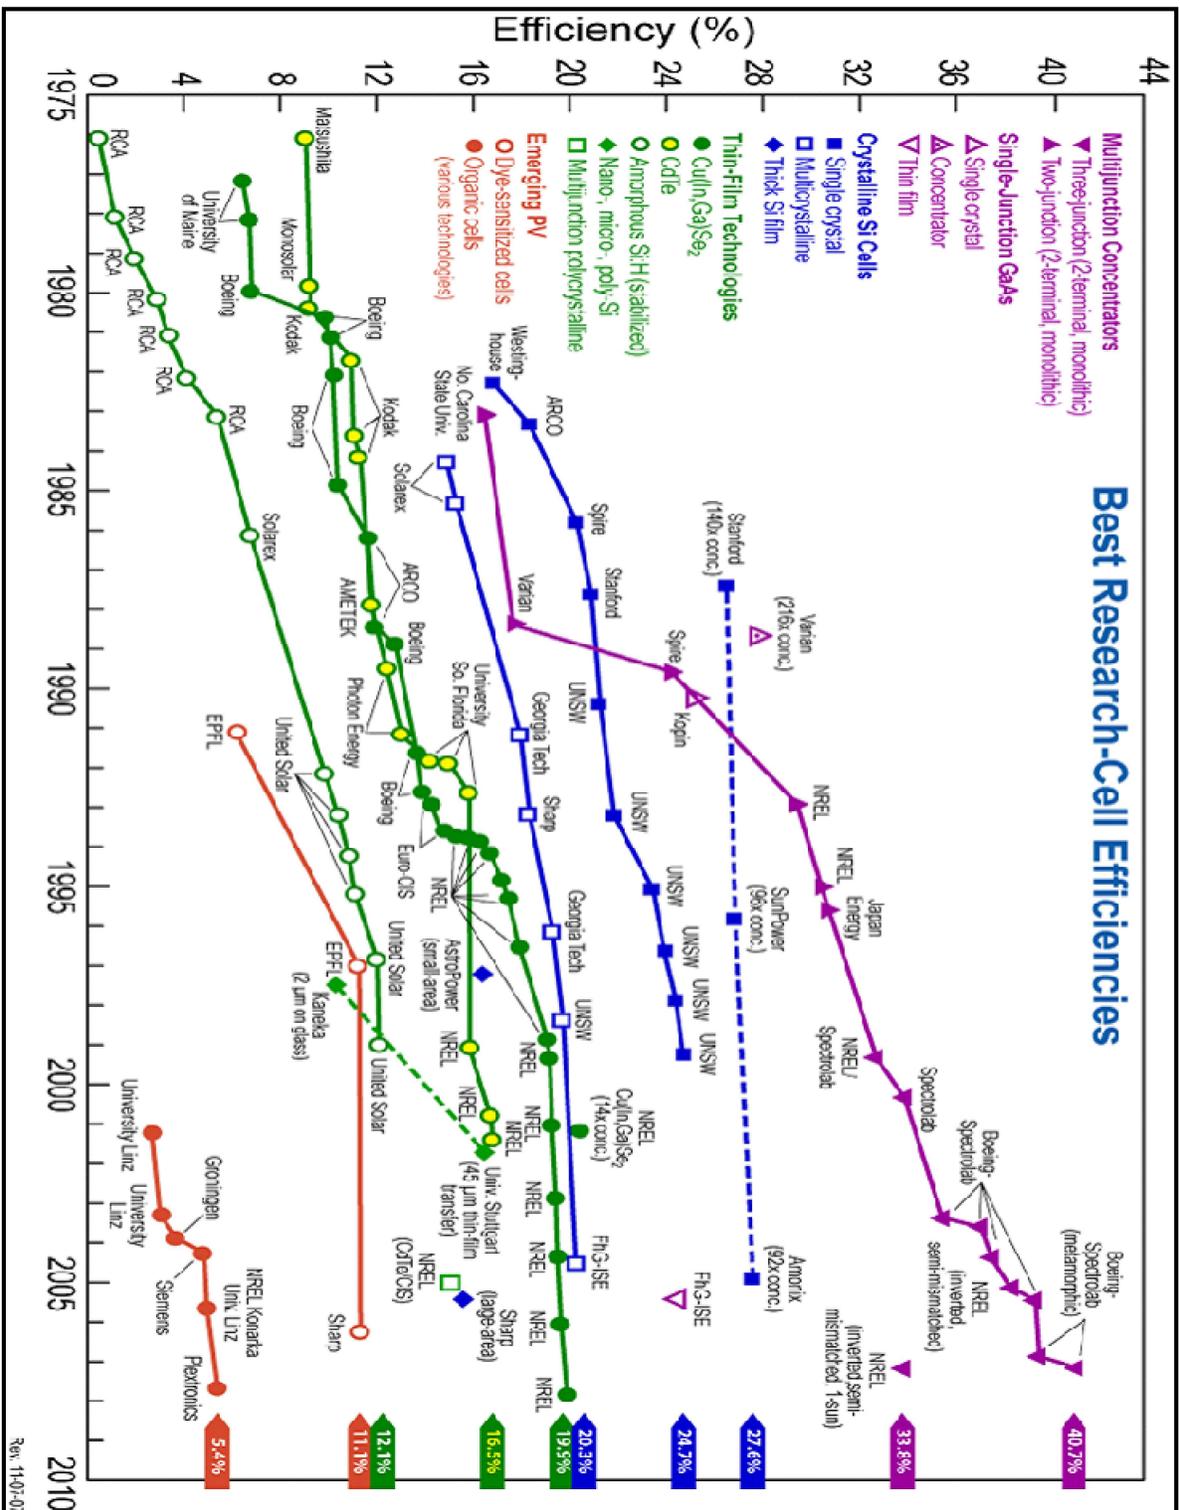


Figura 1.6 Eficiencias de conversión de los distintos tipos de celdas solares [24]

1.3.2.2.- Paneles fotovoltaicos policristalinos

Este tipo de módulos fotovoltaicos están formados por varios cristales de silicio. Estos módulos presentan eficiencias de conversión un poco inferiores a las monocristalinas, pero han llegado a obtenerse hasta eficiencias del 15% a nivel comercial. En pruebas de laboratorio se han alcanzado eficiencias del 20% y pueden predecirse un alto rendimiento en 25 años de producción de electricidad [24]. Actualmente el panel policristalino es el más versátil y adaptable, con potencias de 220 a 300 W. Es adecuado para instalaciones a gran escala debido a que tienen un menor costo de producción.

1.4 Celdas de Hidrógeno.

En general, los diseños de microredes eléctricas consideran como método de almacenamiento el uso de baterías de plomo-ácido, debido a su bajo costo. Sin embargo, el impacto ambiental de estos dispositivos es alto al momento de desecharlas y su tiempo de vida es relativamente corto, aproximadamente 7 años en baterías de ciclo profundo. En los últimos años, el almacenamiento de energía utilizando hidrógeno y su posterior aprovechamiento en celdas de combustible se ha considerado como una buena opción para reemplazar el uso de baterías. Las celdas de combustible generan electricidad a partir de la oxidación electroquímica de hidrógeno y la reducción de oxígeno con una eficiencia alrededor del 40% y con bajas emisiones de gases contaminantes [4]. Con esquemas de recuperación del calor, la eficiencia de una celda de combustible puede incrementarse hasta un 80%.

1.5.- Redes neuronales artificiales.

Una red neuronal artificial es un procesador paralelo distribuido formado por unidades de procesamiento (neuronas) y cuya función es almacenar conocimiento adquirido de manera experimental y generalizar para estímulos similares. El conocimiento es adquirido por la red a través de un proceso de aprendizaje por ejemplos 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 [25].

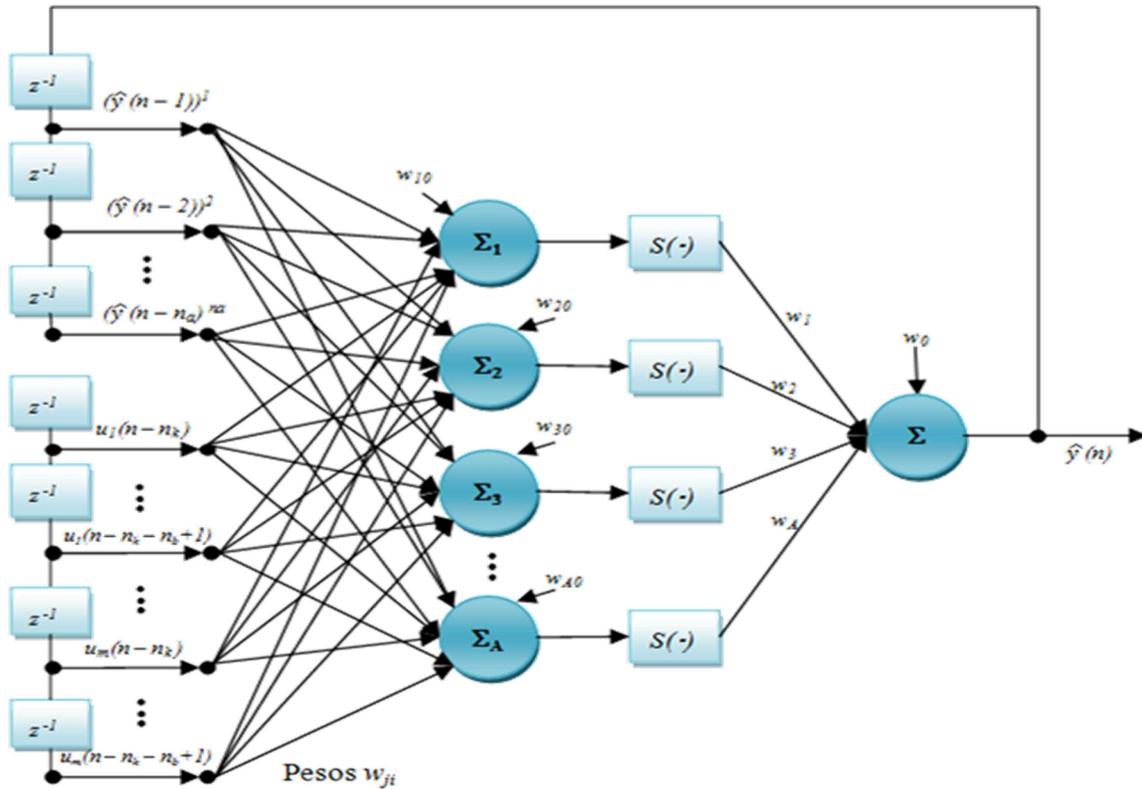


Figura 1.7.- Representación esquemática de una red neuronal [25].

1.6.- Topologías de una microred eléctrica inteligente.

La combinación de la celda de combustible y un sistema solar fotovoltaico en una microred eléctrica presenta excelentes ventajas. Usualmente, el respaldo energético en ausencia de generación fotovoltaica es mediante baterías o un generador diésel; el uso de hidrógeno como método de almacenamiento energético elimina el uso de baterías y en consecuencia reduce el impacto ambiental. Por otra parte, un sistema de producción y almacenamiento de hidrógeno se puede alimentar con el sistema fotovoltaico para posteriormente hacer uso de sus excedentes de potencia en la celda de combustible. Las pérdidas de potencia también se verán disminuidas ya que la celda de combustible puede

ser ubicada cerca del centro de carga gracias a sus características de ser silenciosa y cero emisiones [26]. Para redes principalmente alimentadas por sistemas fotovoltaicos existe la necesidad de contar con un sistema de respaldo. En un sistema interconectado a red, ésta sería el respaldo principal, sin embargo, la intermitencia del sistema fotovoltaico presentaría problemas de fluctuaciones de carga para la red pública en aplicaciones de gran escala. Una solución para mantener el suministro de potencia es la inclusión de la celda de combustible que tiene la capacidad de suavizar las oscilaciones en la potencia de salida. Con el respaldo de la celda de combustible se le puede permitir al sistema fotovoltaico trabajar a potencia plena. Coordinados por el controlador de la microred, la celda de combustible suministrará la diferencia entre la demanda del edificio y la producción del sistema fotovoltaico.

1.6.1 Sistema híbrido de generación eléctrica (SHGE)

Un SHGE es la integración de dos o más tecnologías (solar, biomasa, eólica, etc.) con el propósito de proveer energía eléctrica equivalente a la red convencional [26].

En la figura 1.8 se presenta el diseño típico de un SHGE, en donde se indican las fuentes de generación, elementos de conversión de energía y control, almacenamiento de energía y carga.

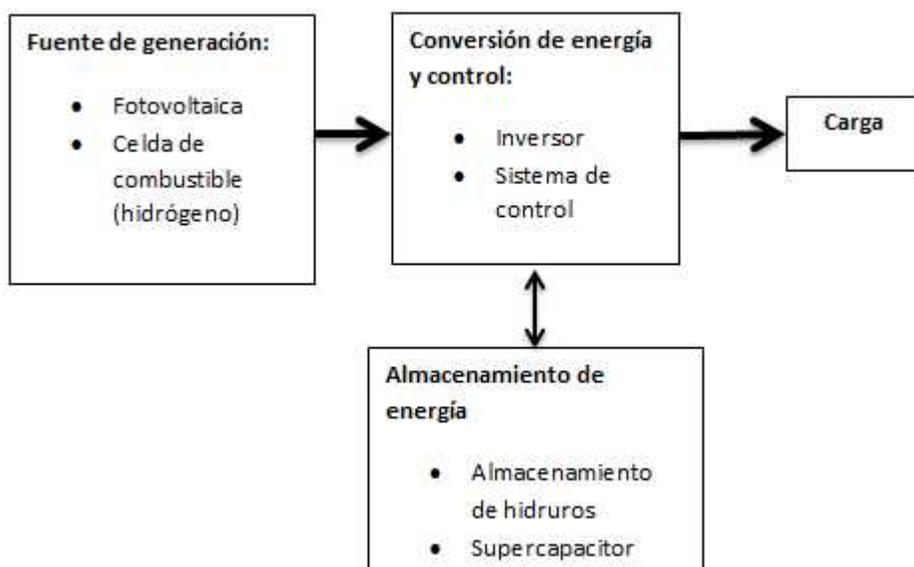


Figura 1.8.- Diagrama a bloques de un SHGE [27].

Estos sistemas son utilizados para la electrificación de zonas aisladas de la red eléctrica, ya que una de sus ventajas es la cuestión económica y ambiental. En la actualidad varias partes del mundo tienen instalado sistemas híbridos como, Australia, Canadá, China, México, etc. [26].

Los SHGE se pueden clasificar dentro de dos topologías: serie y paralelo [5]. Las topologías en paralelo se pueden clasificar como topología paralelo con acoplamiento en CD (corriente directa) o topología paralelo con acoplamiento en CA (corriente alterna) [28]

1.6.2 Topología en serie.

En los SHGE de topología en serie [5], el sistema fotovoltaico está conectado en serie con el electrolizador, el cual convierte la energía, proporcionada por el arreglo fotovoltaico (FV), en hidrógeno. Posteriormente el hidrógeno se almacena en un hidruro metálico. Dicho contenedor se encuentra conectado con la celda de combustible como suministro para generar potencia eléctrica que entrega a la línea eléctrica. El supercapacitor se encuentra conectado directamente a la línea eléctrica, donde el FV suministra la energía requerida para su función. La capacidad instalada de la celda de combustible y del supercapacitor debe ser suficiente para cubrir la demanda pico de la carga

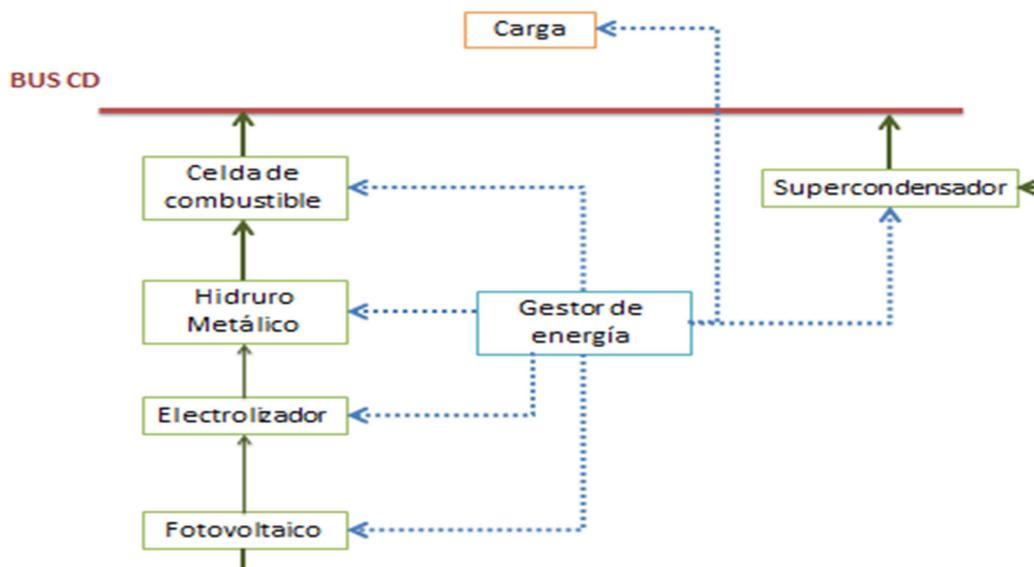


Figura 1.9.- Topología serie del SHGE

1.6.3 Topología en paralelo con acoplamiento en CD.

Los SHGE con topología en paralelo [5], (Figura 1.10) tienen un funcionamiento más confiable que los sistemas con topología serie, ya que pueden continuar operando en ausencia de una fuente. En este esquema, el arreglo fotovoltaico, el supercapacitor y la celda de combustible suministran una porción de la demanda de la carga directamente, lo que resulta en una mayor eficiencia de todo el sistema.

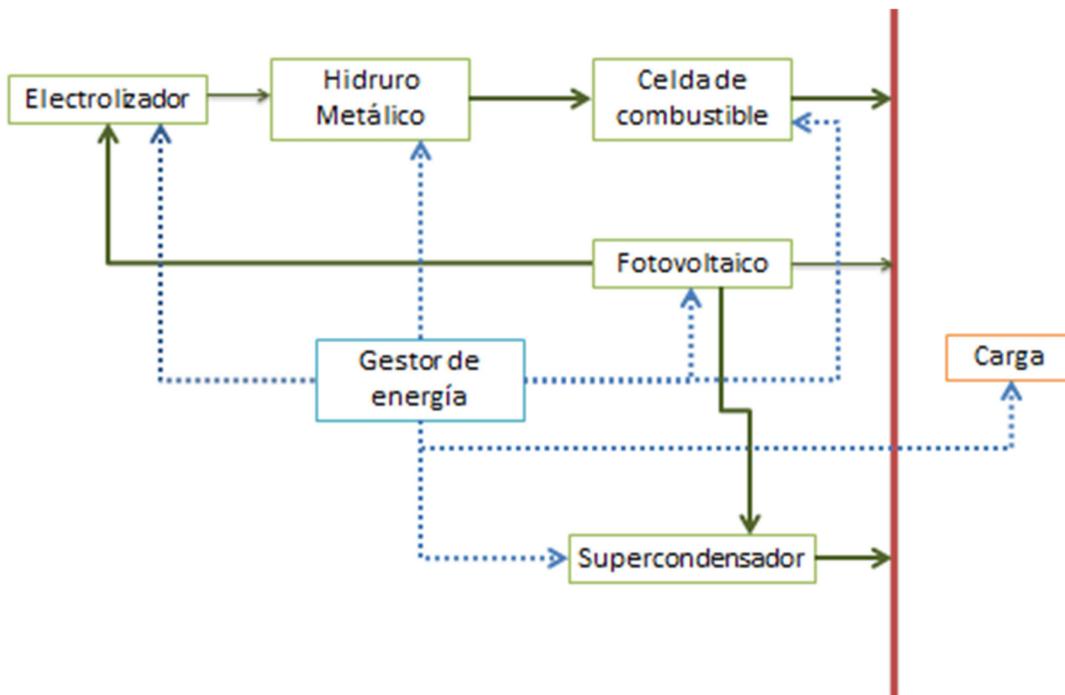


Figura 1.10.- Topología en paralelo del SHGE

El sistema fotovoltaico, la celda de combustible y el supercapacitor pueden operar en modo separado (stand-alone) o paralelo. Esto ofrece diferentes combinaciones de componentes para alimentar a la carga. Cuando la carga es baja, ya sea la celda de combustible o el supercapacitor en modo stand-alone pueden alimentarla. Sin embargo, durante la demanda pico, ambos elementos se operan en modo paralelo con el propósito de satisfacer la demanda eléctrica.

1.7.- Hipótesis

Se puede simular el comportamiento de una microred eléctrica inteligente con generación fotovoltaica, celda de combustible y métodos de almacenamiento de hidrógeno utilizando técnicas de predicción y gestión energética basadas en redes neuronales artificiales.

1.8.- Objetivos

General:

Simular la operación de un sistema híbrido integrado por un sistema fotovoltaico, celda de combustible, almacenamiento de hidrógeno y una fuente de respaldo basado en un supercapacitor dentro de una microred eléctrica inteligente con un sistema de gestión mediante redes neuronales artificiales.

Específicos:

- Obtener los modelos matemáticos de un arreglo de paneles fotovoltaicos, una celda de combustible y un sistema de producción y almacenamiento de hidrógeno a partir de modelos reportados en la literatura.
- Diseñar un algoritmo basado en redes neuronales artificiales para aproximar a los valores reales la generación de potencia, las curvas corriente-voltaje de los sistemas fotovoltaicos y de la celda de combustible.
- Aplicar un algoritmo basado en redes neuronales artificiales para resolver el problema de una gestión óptima de las cargas en la microred considerando cargas críticas y cargas ordinarias.
- Validar los algoritmos de aproximación de la generación de potencia y gestión de cargas en la microred en un entorno de simulación.

CAPITULO 2

METODOLOGÍA

En este capítulo, se describen los elementos que componen la red eléctrica inteligente. Se derivan los modelos matemáticos del sistema fotovoltaico y se describen las características del modelo comercial seleccionado para las simulaciones. Los modelos matemáticos son validados en simulación utilizando la paquetería SIMULINK del MatLab. Estos modelos matemáticos serán posteriormente utilizados en la simulación de la operación de la microred eléctrica inteligente usando las predicciones de generación de potencia realizadas por las redes neuronales. Las redes neuronales se implementan y entrenan utilizando solamente datos experimentales; el modelo en simulación desarrollado en esta tesis es utilizado para garantizar las propiedades de aproximación de curvas de potencia eléctrica y solución del problema de gestión energética.

2.1.- Modelo matemático del sistema fotovoltaico

El modelo corriente-voltaje de una celda fotovoltaica se define por el modelo de diodo propuesto por [29-30], donde la ecuación del diodo Shockley es utilizada para describir la corriente que fluye a través de diodo I_d

$$I_d = I_0 \left(\exp \left(\frac{q(V_{PV} + I_{PV}R_s)}{AKT} \right) - 1 \right)$$

donde V_{PV} es la diferencia de potencial en las dos terminales del diodo, I_0 es la corriente de saturación inversa, A es el factor de idealización, K es la constante de Boltzmann ($1.380650 \times 10^{-23} \frac{J}{K}$) y T es la temperatura de operación.

La expresión para la corriente de salida del módulo fotovoltaico se obtiene a partir de

$$I_{PV} = I_{ph} - I_0 \left(\exp \left(\frac{q(V_{PV} + I_{PV}R_s)}{AKT} \right) - 1 \right) - \frac{V_{PV} + I_{PV}R_s}{R_{sh}} \quad (1)$$

$$I_0 = I_{or} \left(\frac{T}{T_r} \right)^3 \exp \left(\frac{qE_G}{KA} \left(\frac{1}{T_r} - \frac{1}{T} \right) \right) \quad (2)$$

$$I_{ph} = \left(I_{sc} + k_i (T - T_r) \right) \frac{\text{}}{100} \quad (3)$$

donde I_p es la corriente de salida de la celda, I_{ph} es la corriente por efecto fotoeléctrico, I_0 es la corriente de saturación del diodo, I_s es la corriente de corto circuito, E_G es el ancho de banda para el silicio, k_i el coeficiente de temperatura de corto circuito a I_s , q es la carga del electrón, R_s, R_{sh} son las resistencias en serie y shunt respectivamente, T_r la temperatura de referencia, V_p el voltaje de salida de la celda y la radiación solar. Se puede apreciar que un incremento en la temperatura del módulo tiene un efecto negativo sobre la corriente generada. El modelo matemático descrito por las ecuaciones 1-3, involucra ecuaciones implícitas trascendentales que requieren ser resueltas por métodos numéricos para determinar las raíces de I .

En este proyecto se trabajó con un arreglo fotovoltaico compuesto de módulos fotovoltaicos S60MC donde cada uno tiene 60 celdas solares monocristalinas con una potencia total de 250 W. La Figura 2.1 muestra la curva I-V de este panel, tomada de la hoja de datos del fabricante Solartec (Anexo 1). El modelo comercial S60MC tiene las siguientes especificaciones:

Número de celdas: 60 (6x10)

Dimensión del Módulo: 1640 mm x 992 mm

Peso: 20.5 kg

Cable: 90 cm x 4.0 mm²

Marco: Aluminio 40 mm

Clasificación: Clase C

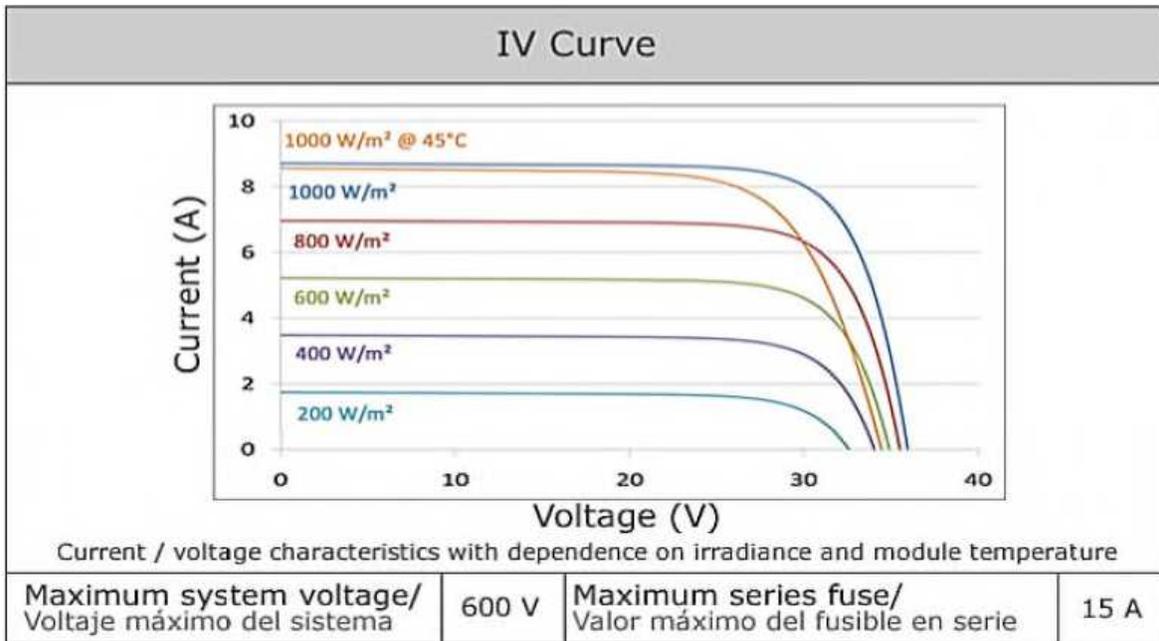


Figura 2.1.- Curvas I-V del panel fotovoltaico S60MC [Anexo 1]

2.2.1 Curva de voltaje-corriente de los módulos fotovoltaicos

Para obtener una expresión que represente la curva Voltaje-Corriente (V-I) del sistema fotovoltaico, se diseñó una red neuronal multicapa con 10 neuronas en la capa oculta y 1 neurona en la capa de salida. Para validar con el mayor número de datos posibles las curvas V-I, los datos para entrenar la red se tomaron de un simulador, como se muestra en la Fig. 2.2 y el Anexo 2, con los datos de fábrica del modelo comercial S60MC de 5 niveles de radiación solar con incrementos de 200 W/m² en un rango entre 200 y 1000 W/m², y 10 niveles de temperatura con incrementos de 5° en un rango entre 25 y 70 °C para un total de 100,000 datos. En la práctica es posible obtener estos datos utilizando un trazador de curvas I-V y modificando la temperatura del panel. Las variables de entrada a la red fueron: irradiación (W / m²), temperatura (K), voltaje (V) y la salida de la red es la estimación de la corriente (A). La figura 2.3 muestra las curvas voltaje-corriente y voltaje-potencia para distintas amplitudes de irradiación y a una temperatura de 25°C.

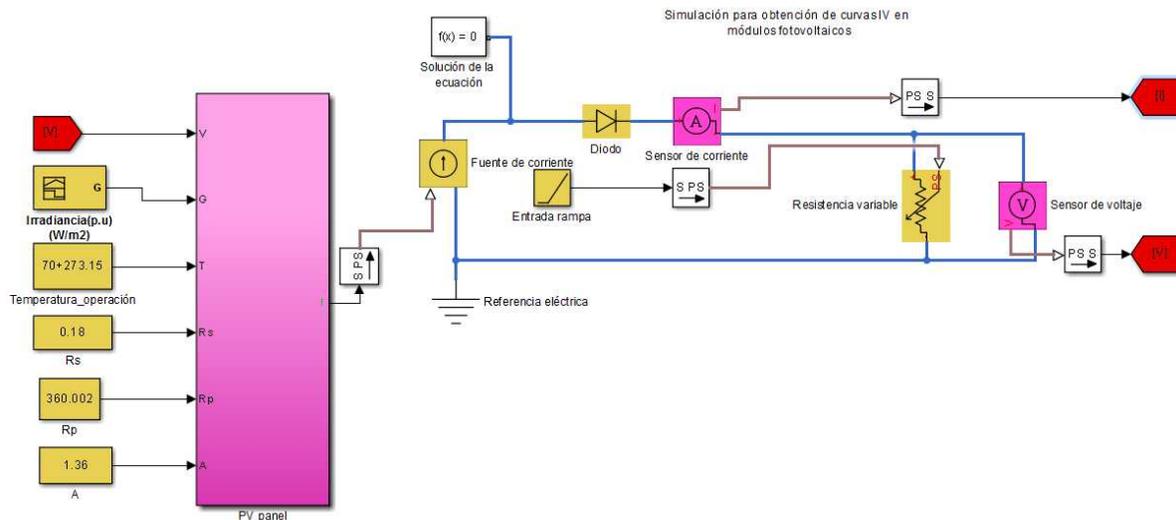


Figura 2.2.- Diagrama en Simulink para obtención de corriente y voltaje de un panel fotovoltaico.

Tabla 2.1.- Parámetros de simulación de una curva I-V y curva de potencia para el módulo S60MC.

Parámetro	Valor para modelo S60MC
Corriente de corto circuito (I_{sc})	8.62 A
Voltaje de circuito abierto	37.92 V
Corriente de máxima potencia	8.07 A
Voltaje de máxima potencia	30.96 V
Coefficiente de temperatura para voltaje de circuito abierto (k_v)	-0.346 %/ °C
Coefficiente de temperatura para corriente de corto circuito (k_i)	+0.036 %/ °C
Coefficiente de temperatura para corriente de corto circuito (k_p)	-0.47 %/ °C
Número de celdas	60

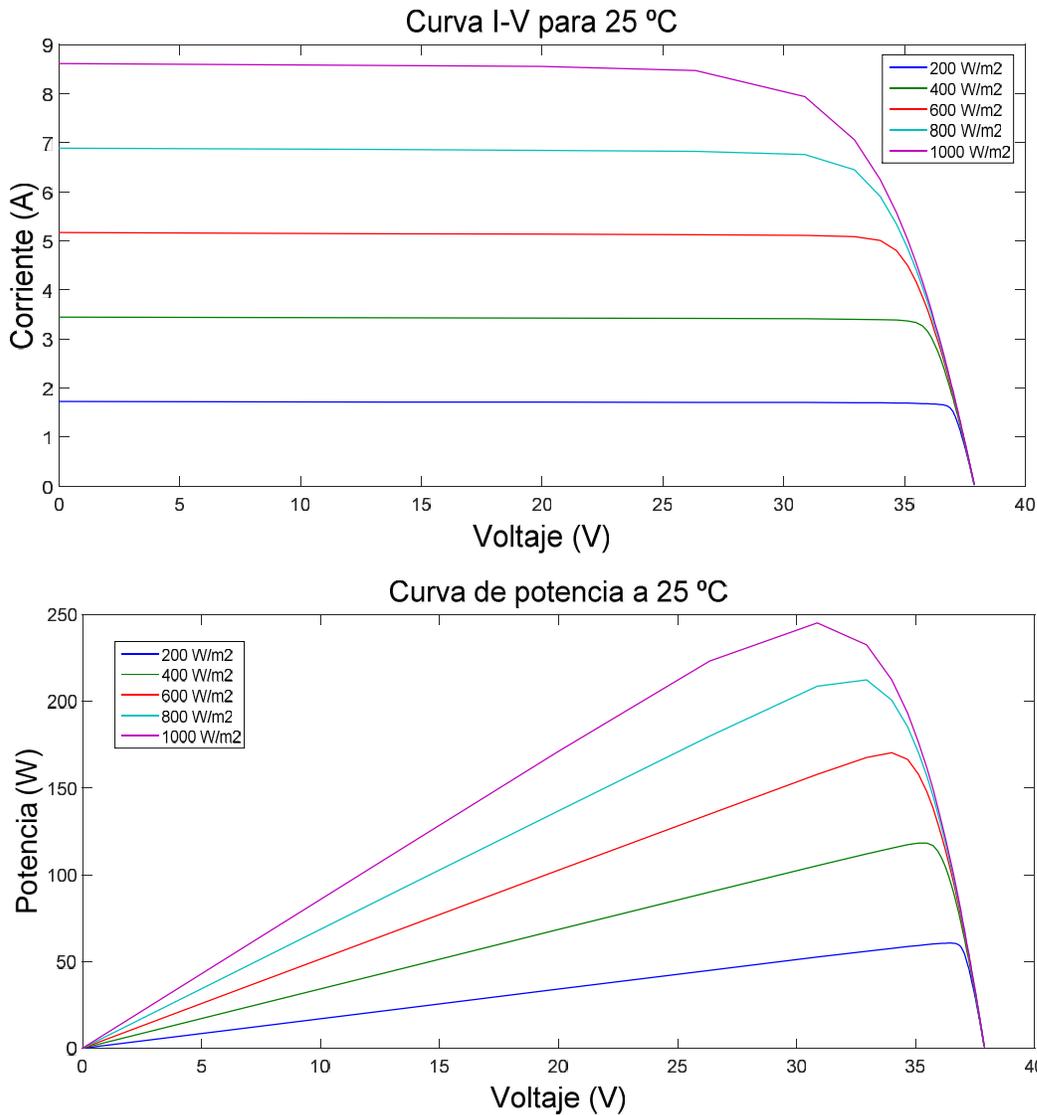


Figura 2.3.-Curva I-V y Curva de potencia a 25° C para diferentes rangos de irradiancia en un panel de S60MC.

2.2.- Modelos matemáticos de la celda de combustible.

En la literatura se han reportado modelos matemáticos de celdas de combustible que han considerado modelos estáticos que representan la curva de polarización, modelos dinámicos linealizados en un punto de operación, modelos dinámicos no lineales, y aproximaciones computacionales basados en lógica difusa y redes neuronales [31]. En particular, para un sistema de gestión de microrred un modelo estático no podría ser

utilizado para satisfacer una demanda eléctrica variante en el tiempo ya que está diseñado en condiciones estacionarias y es preferible utilizar modelos dinámicos como los desarrollados en los trabajos de Moreira y Saisset [32-33]. Por otra parte, los modelos linealizados presentan un gran error en comparación con los resultados obtenidos en pruebas experimentales.

2.2.1- Modelo semi-empírico de la celda de combustible.

Un enfoque para el modelado de celdas de combustible es el uso de modelos semi-empíricos que se basan en el desarrollo de ecuaciones semi-empíricas cuyos coeficientes pueden ser obtenidos por experimentación y un análisis de regresión lineal [32]. Moreira, propone un modelo de nueve parámetros que puede ser utilizado en aplicaciones de pequeñas redes de distribución eléctrica [32]. Este modelo consiste solamente de una expresión cuyos parámetros son obtenidos mediante un método de ajuste por mínimos cuadrados. Este modelo, a pesar de su simplicidad, considera las principales variables en la operación de la celda de combustible: temperatura de operación, densidad de corriente, presión en ánodo y cátodo. Este modelo semi-empírico fue validado mediante datos experimentales en modelos comerciales con una buena precisión al aproximar adecuadamente el comportamiento de la celda real.

El voltaje de salida de la celda está dado por,

$$\begin{aligned}
 V_{cell} &= \xi_1 - \xi_3 T \ln(P_{an} - 0.5P_{satH_2O}) - \xi_4 T \ln(P_{ca} - 0.5P_{satH_2O}) - \xi_4 T \ln(P_{ca} - P_{satH_2O}) \\
 &= \xi_2 T + \xi_5 T \ln i + \xi_6 i + \xi_7 T i + \xi_8 i^2 + \xi_9 T^2 i
 \end{aligned} \tag{4}$$

donde V_c es el voltaje de la celda, T es la temperatura, P_a y P_c son las presiones en el ánodo y cátodo respectivamente y P_{s, H_2O} es la presión de saturación del agua. Tomando en cuenta que V_c se puede calcular proporcionando los valores de ψ_1, ψ_3, ψ_4 y una vez que V_c, T, P_a y P_c son conocidos, los otros parámetros ψ_j , para $j= 2, 5, 6, 7, 8, 9$ están asociados con la corriente de la celda de combustible, i y la temperatura T . Los parámetros ψ_j son determinados experimentalmente y su resultado se muestra en la Tabla 2.3.

Tabla 2.2.- Los parámetros del modelo para el módulo de potencia BPS Nexa.

Parámetro	Valor	Parámetro	Valor
1	5.6985×10^{-1}	6	-5.3332×10^{-1}
2	9.4309×10^{-4}	7	3.1428×10^{-3}
3	8.6100×10^{-5}	8	8.1278×10^{-5}
4	9.7550×10^{-5}	9	-4.712×10^{-6}
5	-1.5304×10^{-5}		

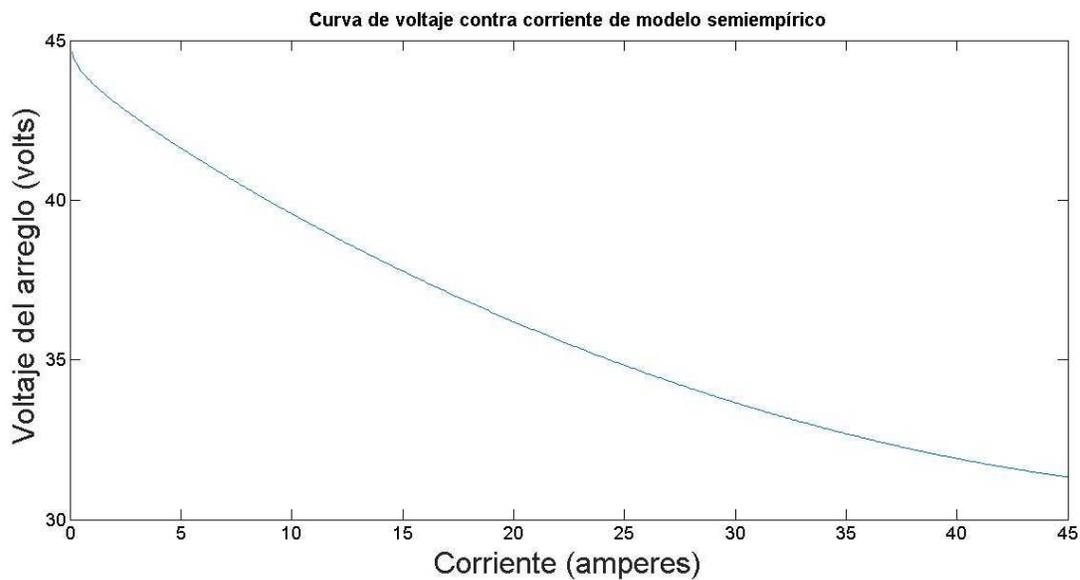


Figura 2.4.- Curva de voltaje contra corriente para el modelo semi-empírico de Moreira [32]

2.2.2 Modelo dinámico de celda de combustible para integración a la microred

En esta sección se describe el modelo dinámico de la celda de combustible que puede ser utilizado para simulación de la operación de una microred eléctrica [34]. Este modelo dinámico es particularmente útil para diseñar técnicas de operación en sistemas de generación de energía aislados y conectados a red [34]. Para el desarrollo de este modelo

se suponen presiones constantes en los canales de distribución de la celda de combustible y las propiedades termodinámicas son consideradas a la temperatura promedio de la celda.

2.2.2.1 Difusión de gas en los electrodos.

En una mezcla compuesta de N gases, la difusión del componente i a través de los electrodos porosos se describe por la ecuación de Stefan-Maxwell dada por

$$\nabla x_i - \frac{R}{P} \sum_{j=1}^N \frac{x_i N_j - x_j N_i}{D_i} \quad (5)$$

donde ∇ es el operador gradiente, x_i la fracción molar, D_i la difusividad binaria efectiva del par de gases i - j , N_j el flujo superficial del gas j , T la temperatura del gas y P es la presión de la mezcla de gas. Las presiones parciales del hidrógeno y oxígeno se requieren para calcular el voltaje de salida de la celda.

Suponiendo un proceso de transporte unidimensional para H_2O (i) y H_2 (j), la difusión del agua se puede expresar como

$$\frac{d x_{H_2O}}{d} = \frac{R}{P_a} \left(\frac{x_{H_2O} N_{H_2} - x_{H_2} N_{H_2O}}{D_{H_2O,H_2}} \right) = \frac{R}{P_a} \left(\frac{x_{H_2O} N_{H_2}}{D_{H_2O,H_2}} \right) \quad (6)$$

donde P_a es la presión del gas en el ánodo.

El flujo molar N_{H_2} de H_2 se calcula mediante la Ley de Faraday,

$$N_{H_2} = \frac{I_d}{2F} \quad (7)$$

donde I_d es la densidad de corriente y F es la constante de Faraday.

Combinando las expresiones anteriores e integrando se obtiene,

$$x_{H_2O}^* = x_{H_2O}^{ch} e^{-\left(\frac{R d I_a}{2FP_a D_{H_2O,H_2}} \right)} \quad (8)$$

donde l_a es la distancia de la superficie del ánodo al sitio de la reacción. Se supone que el combustible consiste solamente de hidrógeno y vapor de agua, esto es $x_{H_2O}^* + x_{H_2}^* = 1$

La presión parcial efectiva del hidrógeno está definida por

$$P_{H_2}^* = \frac{P_{H_2O}^*}{x_{H_2O}^*} (1 - x_{H_2O}^*) \quad (9)$$

La presión efectiva del vapor en el ánodo es $0.5P_{H_2O}^{S_i}$, por lo tanto

$$P_{H_2}^* = 0.5P_{H_2O}^{S_i} \left[\frac{1}{x_{H_2O}^{ch} e^{\left(\frac{R}{d} \frac{l_a}{2F} \frac{1}{D_{H_2O,H_2}} \right)} - 1} \right] \quad (10)$$

Los gases que fluyen al canal del cátodo son O_2 , N_2 , $H_2O_{(g)}$ y CO_2 . La difusión de $H_2O_{(g)}$ en el cátodo puede definirse como:

$$\frac{d_{H_2O}}{d} = \frac{R}{P_c} \left(\frac{x_{O_2} N_{H_2O} - x_{H_2O} N_{O_2}}{D_{H_2O,O_2}} \right) = \frac{R}{P_c} \left(\frac{-x_{H_2O} N_{O_2}}{D_{H_2O,O_2}} \right) \quad (11)$$

donde P_c es la presión total en el cátodo.

De manera análoga, para el ánodo se pueden calcular las fracciones molares

$$\text{como: } x_{H_2O}^* = x_{H_2O}^{ch} \exp \left(\frac{R}{4F} \frac{d}{c} \frac{l_c}{D_{H_2O,O_2}} \right) \quad (12)$$

$$x_{N_2}^* = x_{N_2}^{ch} \exp \left(\frac{R}{4F} \frac{d}{c} \frac{l_c}{D_{N_2,O_2}} \right) \quad (13)$$

$$\Delta G = \Delta H - T \Delta S = \Delta G_0 - R \ln [P_{H_2}^* \cdot (P_{O_2}^*)^{0.5}] \quad (14)$$

donde l_c es la distancia de la superficie del cátodo al sitio de la reacción. En el cátodo se tiene la fracción molar de O_2

$$x_{O_2}^* = 1 - x_{H_2O}^* - x_{N_2}^* - x_{C_2}^* \quad (15)$$

por lo tanto, la presión parcial efectiva para el O_2 está dada por

$$P_{O_2}^* = \frac{P_{H_2O}^*}{x_{H_2O}^*} x_{O_2}^* = \frac{P_{H_2O}^*}{x_{H_2O}^*} (1 - x_{H_2O}^* - x_{N_2}^* - x_{C_2}^*)$$

Dado que en el cátodo $P_{H_2O}^* = P_{H_2O}^{S_1}$,

$$P_{O_2}^* = P_{H_2O}^{S_1} \left[\frac{1 - x_{N_2}^* - x_{C_2}^*}{x_{H_2O}^*} - 1 \right] \quad (16)$$

Las ecuaciones dinámicas para las presiones parciales efectivas de hidrógeno y oxígeno en los canales del cátodo y ánodo pueden ser determinadas a partir de la ecuación del gas ideal,

$$\frac{V_a}{R} \frac{dP_{H_2}^*}{dt} = M_{H_2,i_1} - M_{H_2,o} - \frac{i}{2F} = M_{H_2,n} - \frac{i}{2F} \quad (17)$$

$$\frac{V_c}{R} \frac{dP_{O_2}^*}{dt} = M_{O_2,i_1} - M_{O_2,o} - \frac{i}{4F} = M_{O_2,n} - \frac{i}{4F} \quad (18)$$

donde V_a es el volumen del ánodo, M_{H_2,i_1} es el flujo molar, i la corriente en la celda de combustible.

En estado estable, dado que las presiones parciales se suponen constantes, se puede escribir

$$\frac{dP_{H_2}^*}{dt} = \frac{dP_{O_2}^*}{dt} \quad (19)$$

$$M_{H_2,n} = 2M_{O_2,n} = \frac{i}{2F} \quad (20)$$

En estado transitorio, existen retardos entre el cambio de corriente de carga y el flujo molar de combustible H_2 y oxidante O_2 . Estos retardos pueden modelarse mediante ecuaciones de primer orden,

$$\tau_a \frac{dM_{H_2,n}}{dt} = \frac{i}{2F} M_{H_2,n} \quad (21)$$

$$\tau_c \frac{dM_{O_2,n}}{dt} = \frac{i}{4F} M_{O_2,n} \quad (22)$$

donde τ_a , τ_c son constantes de tiempo.

2.2.2.2 Voltaje de salida de la celda de combustible.

La reacción en la celda de combustible está dada por



La ecuación correspondiente para determinar el potencial reversible es

$$E_c = E_{O,c} + \frac{R}{2F} \ln [P_{H_2}^* \cdot (P_{O_2}^*)^{0.5}] \quad (24)$$

$E_{O,c}$ es el potencial de referencia, que es función de la temperatura y se define como

$$E_{O,c} = E_{0,c}^\circ - k_E (T - 298) \quad (25)$$

donde $E_{0,c}^\circ$, es el potencial de referencia estándar.

El efecto total de los retardos en el combustible y oxidante se representa por el voltaje $E_{d,c}$ que es función del tiempo y muestra la influencia de estos retardos en los transitorios de carga. En el dominio de Laplace, $E_{d,c}$ se expresa como

$$E_{d,c}(s) = \lambda_e I(s) \left(1 - \frac{1}{\tau_e s + 1}\right) = \lambda_e s(s) \frac{\tau_e s}{\tau_e s + 1} \quad (26)$$

donde λ_e es una constante y τ_e representa el retardo total.

Para expresar este voltaje en dominio del tiempo tenemos

$$E_{d,c} = \lambda_e [i(t) - i(t) \otimes e^{-t/\tau_e}] \quad (27)$$

donde \otimes es el operador de convolución.

Para tomar en cuenta las pérdidas por retardos, el voltaje de circuito abierto de la celda puede reescribirse como

$$E_c = E_{O,c} + \frac{R}{2F} \ln [P_{H_2}^* \cdot (P_{O_2}^*)^{0.5}] - E_{d,c} \quad (28)$$

$$V_c = E_c - V_{a,c} - V_{ohm,c} - V_{c,c} \quad (29)$$

Por lo tanto, el voltaje de un arreglo de celdas de combustible se define como

$$V_o = N_c V_c = E - V_a - V_{ohm} - V_c \quad (30)$$

2.2.2.3 Caídas de voltaje en la celda.

Pérdidas de voltaje de activación. Estas pérdidas son función de la corriente y temperatura de celda y se definen empíricamente por la ecuación de Tafel,

$$V_a = \frac{R}{\alpha} \ln\left(\frac{I}{I_0}\right) = T \cdot [a + b \ln(I)] \quad (31)$$

Redefiniendo V_a tenemos,

$$V_a = \eta_0 + (T - 298) \cdot a + T \cdot b \ln(I) = V_{a_1} + V_{a_2} \quad (32)$$

donde η_0 , a , b son constantes empíricas. $V_{a_1} = \eta_0 + (T - 298) \cdot a$ son las pérdidas debidas a la temperatura de la celda y $V_{a_2} = T \cdot b \ln(I)$ depende de la corriente y la temperatura.

La resistencia equivalente de activación se define por la razón

$$R_a = \frac{V_{a_2}}{I} = \frac{T \cdot b \ln(I)}{I} \quad (33)$$

Pérdidas óhmicas. La resistencia óhmica de la celda de combustible consiste de la resistencia de la membrana y los electrodos.

$$V_{ohm} = V_{ohm,a} + V_{ohm,m} + V_{ohm,c} = I R_{ohm} \quad (34)$$

R_{ohm} puede expresarse como

$$R_{ohm} = R_{ohm0} + k_R I - k_R T \quad (35)$$

donde k_R , k_R son constantes empíricas.

Pérdidas de concentración. Durante el proceso de reacción, los gradientes de concentración se presentan debido a la difusión de masa de los canales de flujo de gas a las superficies del catalizador. A altas densidades de corriente, un bajo transporte de reactantes a los sitios de reacción es la principal razón para la caída de voltaje. El voltaje de concentración está definido por,

$$V_c = \frac{R}{z} \ln \frac{C_S}{C_B} \quad (36)$$

donde C_S es la superficie de concentración en el sitio de reacción, C_B es la concentración en el canal de gas y z el número de electrodos participantes.

De acuerdo con la primera Ley de Fick y la Ley de Faraday, se puede reescribir este voltaje en función de la corriente como

$$V_c = \frac{V_c}{I} \ln \left(1 - \frac{I}{I_{li}} \right) \quad (37)$$

donde I_{li} es la corriente límite de la celda. La resistencia equivalente puede definirse como,

$$R_c = \frac{V_c}{I} = \frac{R}{z} \ln \left(1 - \frac{I}{I_{li}} \right) \quad (38)$$

Efecto de carga de doble capa. En las celdas de combustible los electrodos están separados por una membrana sólida, que permite que sólo los protones de hidrógeno pasen a través de ella, bloqueando el flujo de electrones. Estas capas se comportan como un supercapacitor. El circuito equivalente que considera este efecto se muestra en la figura 2.5.

La caída de voltaje en el capacitor se expresa como

$$V_C = \left(I - C \frac{d\varepsilon}{dt} \right) (R_a + R_c) \quad (39)$$

Integrando el efecto de carga en la doble capa en el modelado, obtenemos la expresión para el voltaje de salida de la celda

$$V_o = E - V_{ac} - V_C - V_{ohm} \quad (40)$$

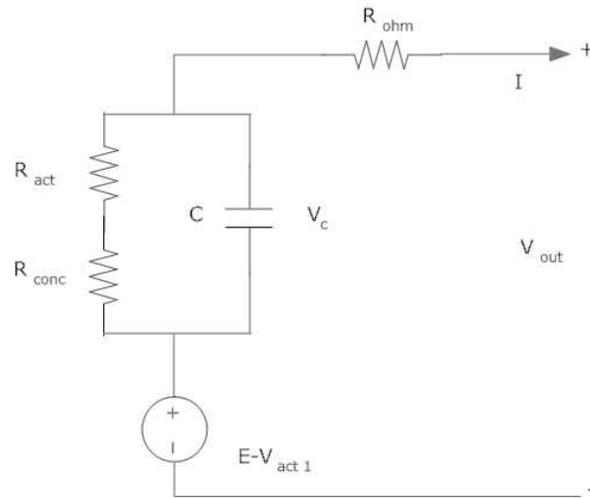


Figura 2.5.- Circuito equivalente del efecto de carga de doble capa

2.2.3 Ecuaciones termodinámicas.

La generación de calor debido a la reacción química en la celda de combustible y que propicia cambios de temperatura está dada por

$$\bar{q}_n = \bar{q}_{che} - \bar{q}_e - \bar{q}_{s, +lc} - \bar{q}_{lc} \quad (41)$$

donde \bar{q}_n es el calor neto (J), \bar{q}_{che} la energía química, \bar{q}_e la energía eléctrica, $\bar{q}_{s, +lc}$ el calor sensible y latente y \bar{q}_{lc} las pérdidas de calor.

La potencia debida a la reacción química dentro de la celda se define como

$$\bar{q}_{chem} = \bar{n}_{H_2, c} \cdot \Delta H \quad (42)$$

donde $\bar{n}_{H_2, c}$ es el H₂ consumido.

La máxima energía eléctrica disponible puede calcularse de la energía de Gibbs como

$$\Delta G = \Delta G_0 - R \ln [P_{H_2}^* \cdot (P_{O_2}^*)^{0.5}] \quad (43)$$

donde ΔG_0 es la energía libre de Gibbs (J/mol), ΔG_0 es la energía libre en condiciones estándar.

Finalmente, la potencia eléctrica de la celda está dada por,

$$\dot{q}_e = V_o \cdot I \quad (44)$$

Por otra parte, el calor sensible y latente $q_{s, l}$ (J) absorbido durante el proceso puede ser estimado a partir de la expresión

$$q_{s, l} = n_{H_2,0} (T - T_r) \cdot C_{H_2} + n_{O_2,0} (T - T_r) \cdot C_{O_2} + n_{H_2O,gen} (T - T_r) \cdot C_{H_2O,l} + n_{H_2O,ge} \cdot H_V \quad (45)$$

donde n_i es el flujo del gas i (mol/s), C_i es la capacidad calorífica del gas i (J/mol), H_V es el calor de vaporización del agua (J/mol) y T_r es la temperatura del entorno en K.

La pérdida de calor, principalmente por convección está dada por

$$\dot{q}_{lc} = h_c (T - T_r) N_c A_c \quad (46)$$

donde h_c es el coeficiente de transferencia de calor por convección (W/m²K).

La temperatura de la celda, se puede obtener a partir del balance de energía como

$$M_F C_F \frac{d}{dt} = \dot{q}_n \quad (47)$$

donde M_F es la masa total del arreglo de celdas y C_F es la capacidad calorífica total del mismo.

La Figura 2.6 muestra un diagrama de bloques con los elementos que integran el modelado dinámico de la celda de combustible [33]. Esta estructura servirá de base para su implementación en un entorno de simulación como la paquetería SIMULINK de MatLab.

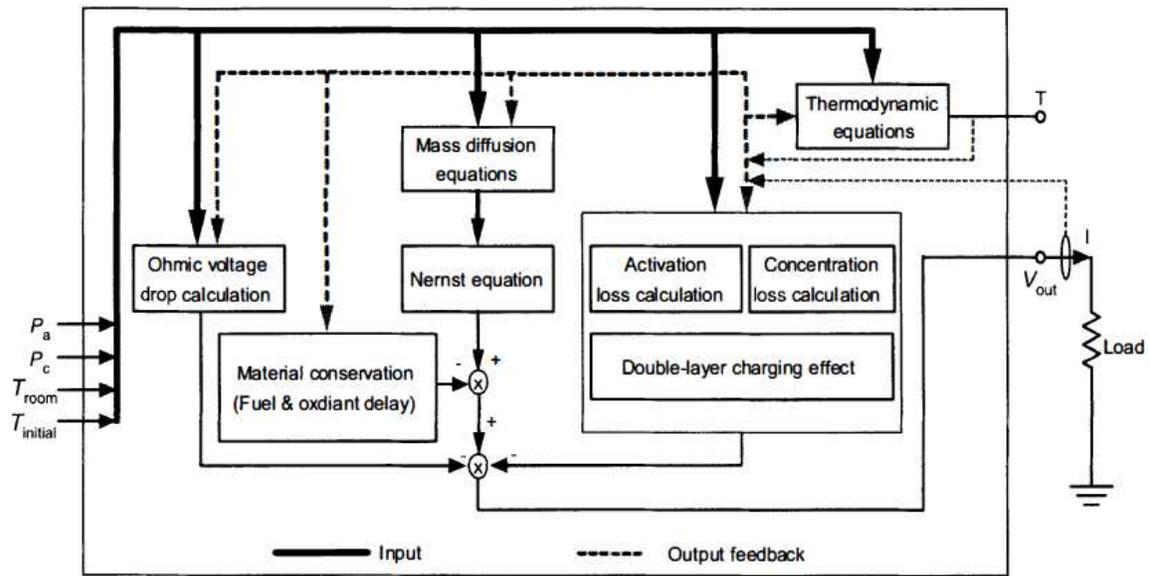


Figura 2.6.- Diagrama de bloques del modelo dinámico de la celda de combustible [33]

El modelo dinámico está basado en las relaciones electroquímicas y termodinámicas que se han revisado. Para este sistema, mostrado en la Figura 2.6, las entradas son las presiones en el ánodo y cátodo, la temperatura inicial de celda y temperatura ambiente. Las salidas son la corriente y temperatura de la celda.

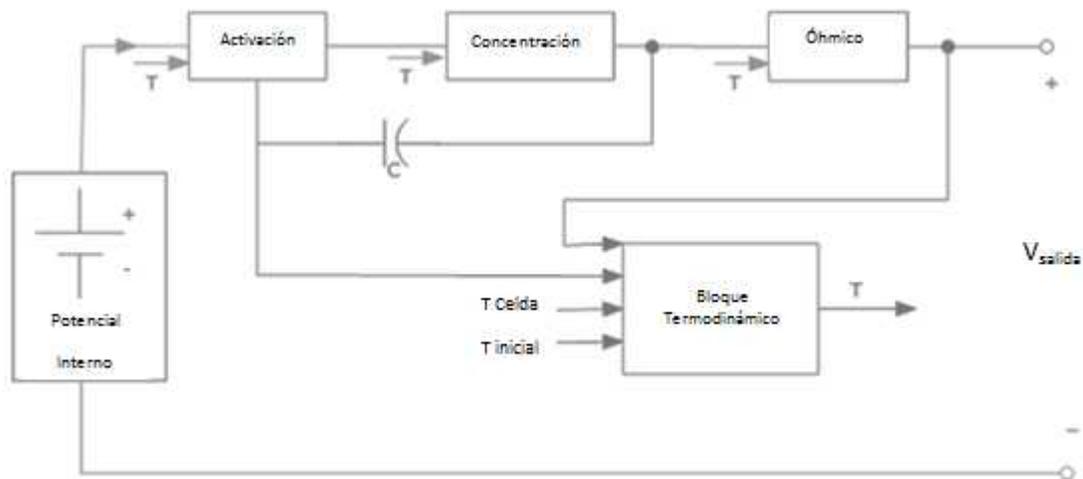


Figura 2.7.- Diagrama de bloques para circuito eléctrico equivalente en una celda de combustible

En la práctica, las celdas de combustible trabajan con otros dispositivos eléctricos. Para obtener un modelo de la celda de combustible que pueda integrarse fácilmente en conjunto con otros elementos eléctricos, se puede utilizar un circuito eléctrico equivalente como el que se muestra en la Figura 2.7.

La fuente de voltaje controlada por corriente y temperatura definida como $f_1(I,T)$. La fuente de voltaje controlada por corriente $f_2(I)$ representa el término $E_{d,c}$, en la ecuación (27) para el número total de celdas en serie (N_c).

$$f_1(I,T) = \frac{N_c R}{2F} \ln [P_{H_2}^* \cdot (P_{O_2}^*)^{0.5}] + N_c K_E (T - 298) \quad (48)$$

$$f_2(I) = N_c E_{d,c}$$

El potencial interno de la celda está dado por

$$E = E_0^0 - f_1(I,T) - f_2(I) \quad (49)$$

La caída de voltaje de activación se puede dividir en dos partes, V_{a1} y V_{a2} , V_{a1} puede ser modelado como una fuente voltaje en serie con una fuente de voltaje controlada por temperatura. V_{a2} puede representarse como una caída de voltaje a través de un resistor R_a dependiente de la temperatura y la corriente. Este resistor está definido usando un modelo polinomial para una fuente de voltaje controlado por corriente.

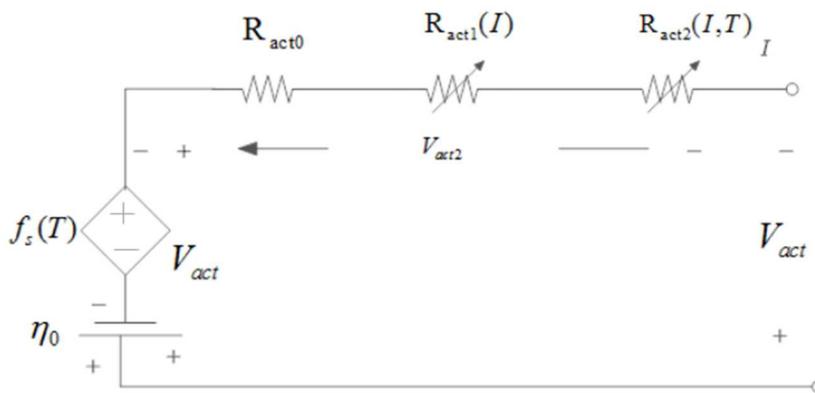


Figura 2.8.- Circuito equivalente para pérdidas de voltaje de activación

Un circuito equivalente para una caída de voltaje de activación se muestra en la Figura 2.8, donde V_{a1} y V_{a2} están dados por:

$$V_{a1} = \eta_0 + f_3(T) = \eta_0 + (T - 298)a \quad (50)$$

$$V_{a2} = (R_a)(I) = (R_{a0} + R_{a1} + R_{a2})(I) \quad (51)$$

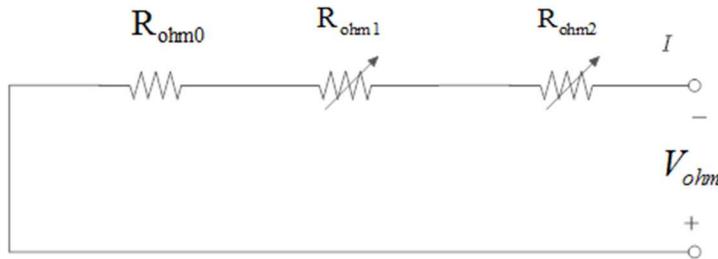


Figura 2.9.- Circuito equivalente para las pérdidas de voltaje óhmicas

El circuito equivalente para las pérdidas óhmicas se muestra en la Figura 2.9. De acuerdo a la ecuación (35), R_{ohm} es un resistor dependiente de la corriente y la temperatura, que se modela de la misma manera que R_a .

$$R_{ohm} = R_{ohm0} + R_{ohm1} + R_{ohm2} \quad (52)$$

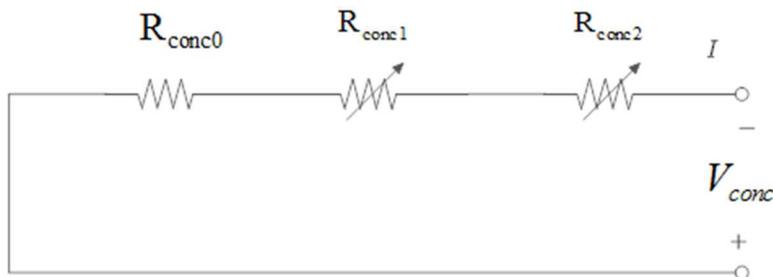


Figura 2.10.- Circuito eléctrico equivalente para caídas de voltaje de concentración

Caída de voltaje por concentración. El modelo eléctrico equivalente se muestra en la figura 2.10, donde la resistencia equivalente por concentración se define como:

$$R_{c_i} = \frac{V_{c_i}}{I} = R_{c_i, 0} + R_{c_i, 1} + R_{c_i, 2} \quad (53)$$

La potencia consumida por las pérdidas de activación, óhmica y de concentración, dado por $(E - V_o) I$, se considera como una fuente de calor que provoca que la temperatura de la celda se incremente. Entonces, la razón de cambio de la fuente de calor (q_{in}) es:

$$q_{in} = (E - V_o) \cdot I \quad (54)$$

La resistencia térmica debida a la convección del aire en la celda de combustible puede expresarse como

$$R_T = \frac{1}{h_c \cdot N_c \cdot A_c} \quad (55)$$

donde h_c es el coeficiente convectivo de transferencia de calor (W/m^2K).

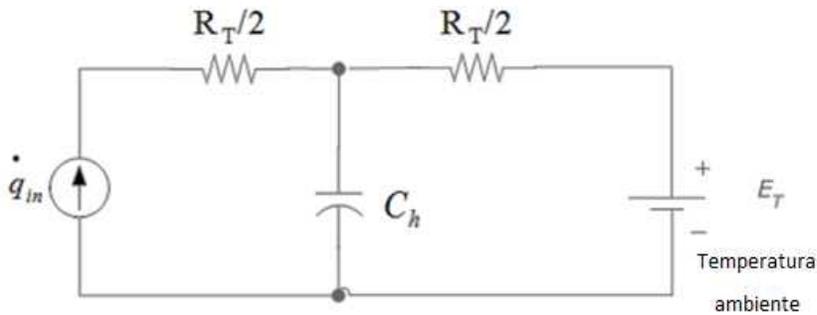


Figura 2.11.-Circuito equivalente para modelar propiedades termodinámicas

En la figura 2.11, la fuente de voltaje constante E_T representa la temperatura del medio, R_T es la resistencia térmica equivalente y C_h es la capacidad calorífica de la celda.

Tabla 2.3.-Parámetros del modelo eléctrico equivalente del Stack SR-12 PEMFC

E_0° (V)	58.9
k_E (V/K)	0.00085
τ_e (s)	80.0
λ_e (Ω)	0.00333
η_0 (V)	20.145
a (V/K)	-0.1373
R_{act0} (Ω)	1.2581
R_{act2} (Ω)	$0.00112 \times (T - 298)$
R_{act1} (Ω)	$-1.6777 \times 10^{-6}I^5 + 1.2232 \times 10^{-4}I^4 - 3.4 \times 10^{-3}I^3 + 0.04545I^2 - 0.3116I$
R_{conc1} (Ω)	$5.2211 \times 10^{-8}I^6 - 3.4578 \times 10^{-6}I^5 + 8.6437 \times 10^{-5}I^4 - 0.010089I^3 + 0.005554I^2 - 0.010542I$
C_h (F)	22000
R_T (Ω)	0.0347
C (F)	0.1F (4.8F for each cell)
R_{ohm0} (Ω)	0.2793
R_{ohm1} (Ω)	$0.001872 \times I$
R_{ohm2} (Ω)	$-0.0023712 \times (T - 298)$
R_{conc0} (Ω)	0.080312
R_{conc2} (Ω)	$0.0002747 \times (T - 298)$

2.3 Modelo de circuito eléctrico equivalente de los supercapacitores basado en redistribución de cargas por difusión.

Los supercapacitores (SC) representan dispositivos de almacenamiento de energía eléctrica, que ofrecen alta densidad de potencia, tiempo de carga corto, un alto número de ciclos y larga vida de duración. Estos dispositivos son de particular interés en las aplicaciones de almacenamiento de energía rápida, donde se requieren de cargas altamente dinámicas. Los supercapacitores por si solos han encontrado aplicaciones en el almacenamiento de energía en nodos sensores autónomos o en combinación con baterías recargables.

Como modelo equivalente se propone el circuito equivalente, que tiene cinco parámetros [35]: C_1 que corresponde a la capacitancia de Helmholtz C_H , C_2 corresponde a la capacitancia difusa C_D , R_1 , representa la equivalencia de la resistencia de la serie (ESR), R_2 representa la resistencia entre las capacitancias de Helmholtz y difusa, R_L representa la resistencia de fuga. La resistencia R_2 es dependiente del tiempo, aumenta con la raíz

cuadrada del tiempo y cubre la probabilidad decreciente para el transporte de otra carga por difusión

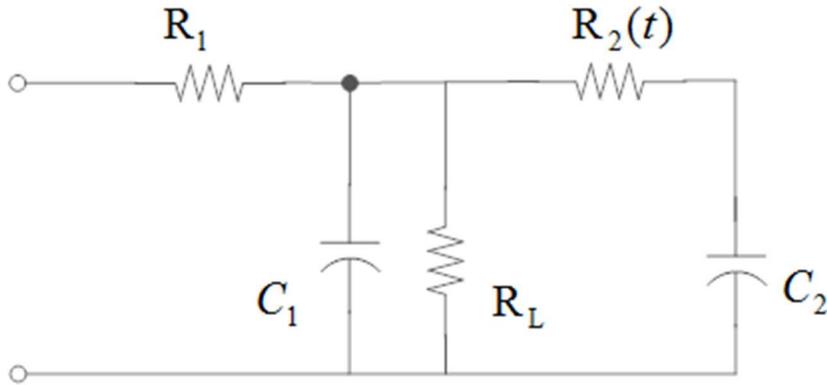


Figura 2.12.-Circuito eléctrico equivalente del supercapacitor

La solución del modelo se basa en los siguientes requisitos:

a) La carga eléctrica almacenada en la capacitancia Helmholtz reacciona inmediatamente con el cambio de voltaje en los electrodos. En este caso el cambio de la carga eléctrica dQ_H es proporcional a la carga de esta capacitancia y el cambio de tiempo d :

$$dQ_H = Q_H \frac{d}{\tau_1} \quad (56)$$

donde Q_H es la carga en Helmholtz capacitancia C_1 y τ_1 es la constante de tiempo que viene dado por el valor de la resistencia capacitancia C_1 y el condensador serie Helmholtz (ESR) denotado en el circuito equivalente como R_1 . Este mecanismo de transporte de carga está involucrado en la componente de la corriente de deriva.

b) La carga eléctrica almacenada en la capacitancia difusa reacciona con el cambio de voltaje en los electrodos con un cierto retraso de tiempo debido al movimiento de cargas eléctricas por difusión. La dependencia del tiempo del cambio de la carga eléctrica dQ_D es proporcional a la Q_D y tiempo de carga cambio d dividido por la raíz de vez multiplicada por la constante de tiempo τ_2 :

$$dQ_D = \frac{Q_D d}{2\sqrt{t\tau_2}} \quad (57)$$

donde Q_D es carga de capacitancia difusa y τ_2 es la constante de tiempo para la difusión de la carga eléctrica. Este mecanismo de transporte de carga está implicado en la componente de corriente difusa.

El modelo de circuito eléctrico equivalente del supercapacitor consta de dos capacitores ideales, dos resistencias ideales y una resistencia en función del tiempo. El método para la determinación de los valores de los parámetros de los componentes ideales es mediante experimentación.

Después de la carga SC por impulso de corriente definido se midió y analizó. La función de análisis para los datos experimentales se ajustó en el intervalo de tiempo del orden de milisegundo es una función exponencial de la tensión contra raíz cuadrada del tiempo, que corresponde a la difusión de carga en el electrolito de la SC. El transporte de carga en la estructura supercapacitor se da tanto por la deriva y difusión. La proporción entre estos dos mecanismos depende probablemente del tipo de electrolito. La constante de tiempo de la componente de corriente de deriva está en el orden de cientos de milisegundos, mientras que la constante de tiempo de la difusión del componente actual es en el orden de cientos de segundos.

El tiempo de resistencia dependiente en el modelo de circuito eléctrico equivalente caracteriza la capacidad de las cargas para mover por difusión desde el volumen del electrolito a la vecindad de la interfaz de electrodo / electrolito. Las funciones analíticas que describen la dependencia del tiempo de la resistencia difusa se derivaron. El valor de la resistencia aumenta con la raíz cuadrada del tiempo, que caracteriza la probabilidad decreciente para el transporte de carga adicionales, portadores por difusión, porque los iones gradiente de concentración disminuye con el tiempo. El modelo con resistencia dependiente del tiempo permite para la descripción de supercapacitores usando circuito eléctrico equivalente con dos ramas RC solamente.

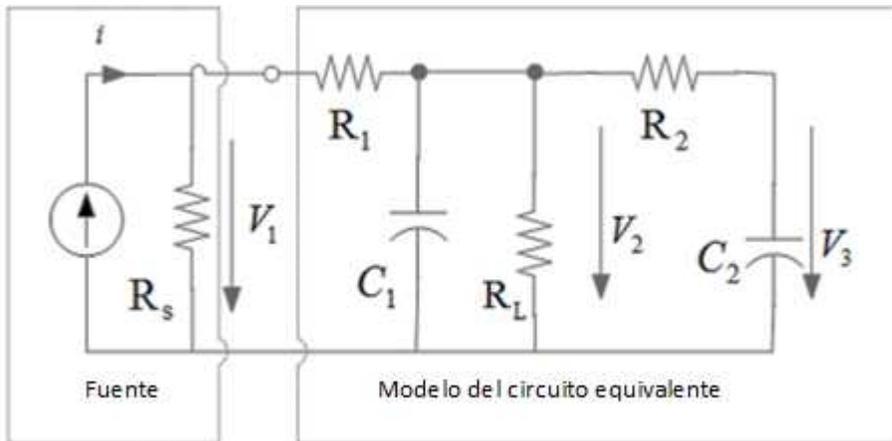


Figura 2.13 -. Circuito eléctrico equivalente con dos ramas RC del supercapacitor

El comportamiento dinámico del supercapacitor, a partir de los cinco parámetros ya descritos, puede sintetizarse por las siguientes ecuaciones:

$$V_1 = \frac{R_s}{R_s + R_1} V_2 + \frac{R_s R_1}{R_s + R_1} i$$

$$\frac{dV_2}{d} = \left(\frac{1}{R_1 C_1} \frac{R_s}{R_s + R_1} - \frac{1}{R_1 C_1} - \frac{1}{R_L C_1} - \frac{1}{R_2 C_1} \right) V_2 + \frac{1}{R_2 C_1} V_3 + \frac{R_s R_1}{C_1 (R_s + R_1)} i \quad (58)$$

$$\frac{dV_3}{d} = \frac{1}{R_2 C_2} V_2 - \frac{1}{R_2 C_2} V_3 + \frac{R_s R_1}{C_1 (R_s + R_1)} i$$

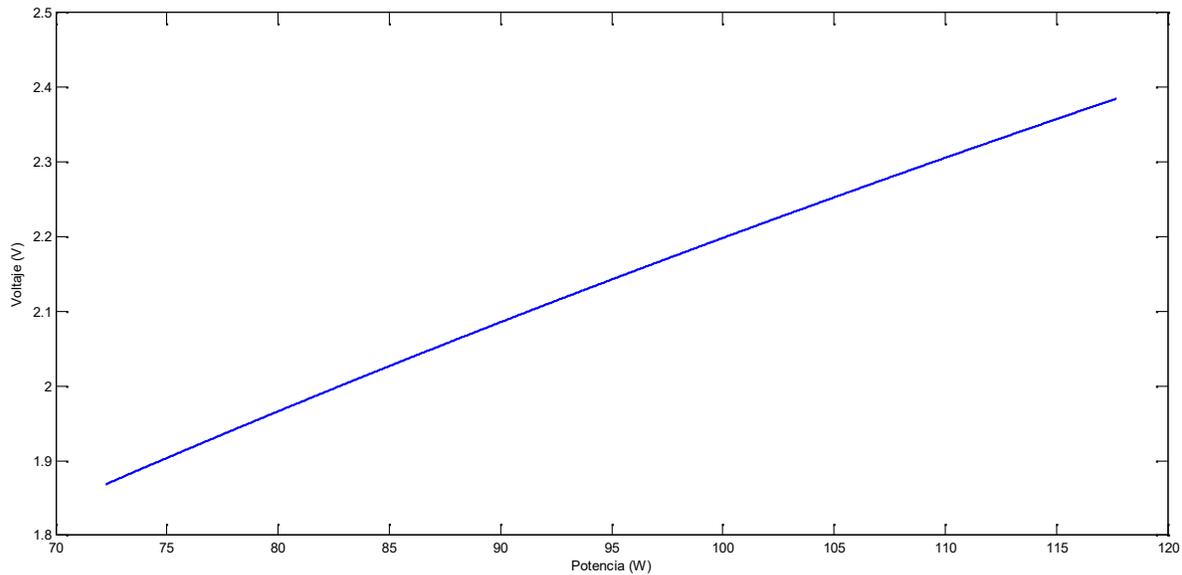


Figura 2.14.- Curva de Potencia para supercapacitor de 10 F y 2.7 V

2.4 Modelo dinámico del electrolizador alcalino

Para obtener las ecuaciones que describen el comportamiento del electrolizador consideramos el modelo presentado en [36]. Para este modelo se supone acerca de la reacción de disociación del agua lo siguiente: (a) el hidrógeno y el oxígeno son gases ideales, (b) el agua es un fluido incompresible, y (c) la fase del gas y líquida son separadas. Basados en estos supuestos, los cambios de entalpía ΔH , entropía ΔS , y energía de Gibbs ΔG de la reacción de la disociación del agua pueden ser calculados con referencia de hidrogeno puro (H_2), oxigeno (O_2) y agua (H_2O) a presión y temperatura estándar (1 bar y 25 °C). El cambio total de la entalpía para la disociación el agua es la diferencia de entalpía entre los productos (H_2 y O_2) y los reactivos (H_2O). Lo mismo aplica para el cambio total de la entropía. El cambio de energía de Gibbs es expresado por:

$$\Delta G = \Delta H - T\Delta S. \quad (59)$$

A condiciones estándar (25°C y 1 bar) la disociación del agua es una reacción no espontánea, lo que significa que el cambio de energía de Gibbs es positivo $\Delta G = 237 \text{ kJ mol}^{-1}$. Para un proceso electroquímico operando a presión constante y temperatura

máxima de trabajo útil es igual al cambio de energía de Gibbs ΔG . La ley de Faraday's se refiere a la energía eléctrica necesario para dividir el agua para la conversión química. La energía eléctrica de un proceso electroquímico reversible o voltaje de la celda reversible esta expresado por:

$$U_{rev} = \frac{\Delta G}{zF} \quad (60)$$

A condiciones estándar $U_r = 1.23 V$ y $U_t = 1.482 V$, pero estos cambiarán con la presión y la temperatura de forma que U_r se reduce ligeramente con el incremento de temperatura.

2.4.1 Modelo electroquímico

La cinética del electrodo de un electrolizador puede usar un modelo empírico corriente-voltaje (I-V). Un modelo empírico I-V para electrolizador a una temperatura predeterminada está dado por

$$U = U_{rev} + \frac{r}{A} + s \log\left(\frac{t}{A} I + 1\right) \quad (61)$$

donde s , t son coeficientes de sobrepotencial, A es el área del electrodo, I es la corriente y r es un parámetro de resistencia óhmica.

Con el fin de expresar adecuadamente la dependencia del sobrepotencial con respecto de la temperatura, la ecuación anterior puede ser modificada con más detalle en un modelo I-V, que tiene en cuenta la temperatura que depende de los parámetros de la resistencia óhmica r y los coeficientes de sobrepotencial s y t .

$$U = U_{rev} + \frac{r_1 + r_2 T}{A} I + s \log\left(\frac{t_1 + t_2 / T + t_3 / T^2}{A} I + 1\right) \quad (62)$$

La eficiencia de Faraday se define como la relación entre la cantidad real y teórica de hidrógeno producido en el electrolizador. Ya que la eficiencia de Faraday es afectada por corrientes parásitas a lo largo del conducto de gas, se le denomina eficiencia de corriente. Las corrientes parásitas aumentan con la disminución de las densidades de corriente debido a una mayor distribución del electrolito y como consecuencia, una resistencia eléctrica más baja. Por otra parte, la corriente parásita en la celda es lineal al potencial de la celda. Una expresión empírica que muestra con precisión estos fenómenos para una temperatura dada es

$$y_F = \frac{(I/A)^2}{f_1 + (I/A)^2} f_2 \quad (63)$$

De acuerdo con la ley de Faraday, la tasa de producción de hidrógeno en una celda de electrolizador es directamente proporcional a la velocidad de transferencia de electrones.

$$\dot{n}_{H_2} = \eta_F \frac{n_c I}{z} \quad (64)$$

$$\dot{n}_{H_2O} = \dot{n}_{H_2} = 2\dot{n}_{O_2}$$

Finalmente, la eficiencia energética de la celda puede ser calculada por la relación entre el voltaje termoneutral y el voltaje de celda.

$$\eta_c = \frac{U_t}{U} \quad (65)$$

2.4.2 Modelo térmico del electrolizador

La temperatura del electrolito del electrolizador se puede expresar como:

$$C_i \frac{dT}{dt} = \dot{Q}_{gen} - \dot{Q}_{loss} - \dot{Q}_{cool} \quad (66)$$

donde \dot{Q}_{gen} es el calor interno generado dado por

$$\dot{Q}_{gen} = y_c (U - U_{in}) I = n_c UI(1 - y_c) \quad (67)$$

\dot{Q}_{gen} es el calor total perdido al ambiente dado por

$$\dot{Q}_{loss} = \frac{1}{R_t} (T - T_a) \quad (68)$$

y \dot{Q}_{cool} es la demanda de refrigeración auxiliar dada por

$$\dot{Q}_{cool} = C_{cw} (T_{cw,i} - T_{cw,o}) = UA_{HX} LMTD \quad (69)$$

$$LMTD = \frac{(T - T_{cw,1}) - (T - T_{cw,0})}{\ln \left[\frac{(T - T_{cw,1})}{(T - T_{cw,0})} \right]}$$

Los parámetros de capacidad térmica C_t , la resistencia R_t para el electrolizador, y UA_H (coeficiente del agua de refrigeración del intercambiador de calor) son constantes que necesitan ser determinadas analíticamente o empíricamente.

Un método simple para calcular la temperatura electrolizador es suponer la razón de generación de calor y transferencia de calor como constante, para un intervalo de tiempo dado. Si los pasos de tiempo se eligen suficientemente pequeños, se obtiene un modelo térmico de estado cuasi-estacionario. Usando este fundamento se aproxima un modelo en estado estable del sistema térmico como

$$T = T_{ini} + \frac{\Delta t}{C_t} (\dot{Q}_{gen} - \dot{Q}_{loss} - \dot{Q}_{cool}) \quad (70)$$

Un método más complejo es resolver la ecuación diferencial analíticamente y calcular la temperatura directamente. Sin embargo, para que esto sea posible primero se requiere determinar una expresión para la salida de agua de refrigeración. Suponiendo una temperatura constante, la ecuación 70 puede reescribirse como

$$T_{cw,0} = T_{cw,1} + (T - T_{cw,i}) \left[1 - \exp\left(-\frac{UA_{HX}}{C_{cw}}\right) \right] \quad (71)$$

A partir de las ecuaciones (66)-(67) se puede demostrar que el balance de energía térmica total en el electrolizador puede ser expresada por una ecuación diferencial lineal, de primer orden, no homogénea

$$\frac{dT}{dt} + aT - b = 0 \quad (72)$$

con solución

$$T(t) = \left(T_{ini} - \frac{b}{a} \right) \exp(-at) + \frac{b}{a} \quad (73)$$

donde

$$a = \frac{1}{\tau_t} + \frac{C_{cw} T_{cw,i}}{C_t} \left[1 - \exp\left(-\frac{UA_{HX}}{C_{cw}}\right) \right] \quad (74)$$

$$b = \frac{n_c UI(1-y_c)}{C_t} + \frac{T_a}{\tau_t} + \frac{C_{cw} T_{cw,i}}{C_t} \left[1 - \exp\left(-\frac{UA_{HX}}{C_{cw}}\right) \right] \quad (75)$$

Una ventaja de tener la expresión analítica para la temperatura es facilitar la determinación de la constante de tiempo térmica $\tau_t = R_t C_t$.

Una expresión empírica que toma en cuenta la transferencia de calor por conducción y convección está dada por

$$U_H = h_c + h_c I \quad (76)$$

La explicación física de este comportamiento es que, dado que el electrolito está en estado estacionario, y no se utiliza una bomba, se supone que el fenómeno de transferencia de calor por convección se incrementa como resultado de la mezcla en el electrolito. Un aumento de la mezcla se produce porque la columna de las burbujas de gas en el electrolito se incrementa al aumentar la densidad de corriente. Por lo tanto, este comportamiento se explica en (76) y en el término de resistencia óhmica en (52).

El modelo de electrolizador alcalino considerado en este trabajo está basado en la planta PHOEBUS en Julich [36]. Los parámetros del modelo real se presentan en las Tablas 2.4-2.6. La Figura 2.15 muestra los resultados en simulación de la producción de hidrógeno de este electrolizador contra la densidad de corriente. Este modelo será utilizado en el siguiente capítulo para su integración con el sistema fotovoltaico.

Tabla 2.4.- Parámetros de curva I-V de electrolizador

r_1	$8.05e - 5\Omega m^2$
r_2	$-2.5e - 7\Omega m^2 \circ C^{-1}$
s	$0.185V$
t_1	$-1.002A^{-1}m^2$
t_2	$8.424A^{-1}m^2 \circ C$
t_3	$247.3A^{-1}m^2 \circ C^2$

Tabla 2.5.- Parámetros de eficiencia de Faraday

	PHOEBUS	HYSOLAR			
T	80	40	60	80	$\circ C$
f_1	2150	150	200	250	$mA^2 cm^{-4}$
f_2	0.96	0.990	0.985	0.980	0....1

Tabla 2.6.- Parámetros UAHX.

h_{cond}	$7W \circ C^{-1}$
h_{conv}	$0.02W \circ C^{-1} (A)$

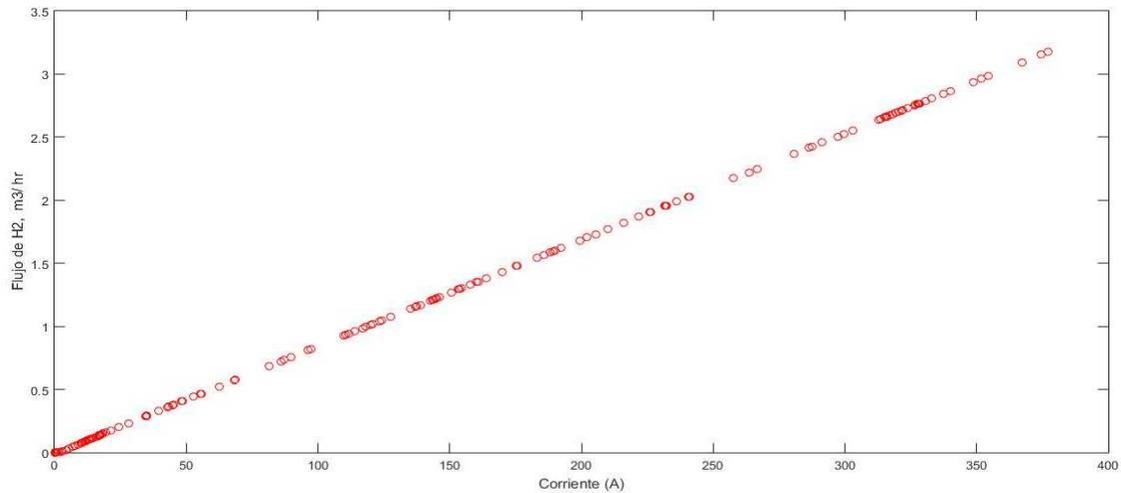


Figura 2.15.- Flujo volumétrico producido por el electrolizador.

2.5.-Generación de potencia para la instalación fotovoltaica.

El primer paso para el diseño de una microred eléctrica inteligente es el adecuado dimensionamiento de las fuentes de generación y almacenamiento del sistema, lo cual se logra a partir de la estimación de la generación fotovoltaica y la demanda del edificio. Las mediciones de generación fotovoltaica para la microred se tomaron a partir de una instalación fotovoltaica de 22 kW ubicada en la Facultad de Ingeniería de la UADY, mostrada en la Fig. 2.16; este sistema se encuentra interconectado a la red pública de distribución eléctrica mediante inversores. La demanda energética también fue determinada a partir de mediciones en el edificio de Energías Renovables de la FIUADY. La capacidad fotovoltaica en el diseño propuesto debe ser suficiente, junto con una adecuada política de consumo y gestión de cargas, para garantizar la sustentabilidad energética de la microred. Los valores de generación energética de esta instalación fueron utilizados para la predicción de generación de potencia utilizada en la simulación del sistema de gestión de la red inteligente.



Figura 2.16.- Sistema de generación de energía fotovoltaica de 22 kW

2.6.- Dimensionamiento de la planta fotovoltaica en la red eléctrica inteligente.

En esta sección se caracteriza la operación de los diferentes elementos que componen la micro red eléctrica. Se dimensiona la planta fotovoltaica, electrolizador y la celda de combustible a partir de los datos de predicción de potencial energético entregados por la red neuronal. Esto para hacer una propuesta de estructura de la microrred que, junto con una política de ahorro energético, pueda satisfacer la demanda; actualmente la instalación existente es insuficiente para este propósito. Posteriormente se integran las fuentes de energía y cargas al sistema de gestión energética para la optimización de su funcionamiento.

La Figura 2.17 muestra las curvas ambientales de irradiación para la ciudad de Mérida; la Tabla 2.6 muestra los valores promedio diarios de irradiación donde puede notarse que los meses de mayor potencial energético son marzo, abril y mayo. En la Tabla 2.6 se enumeran los parámetros necesarios para implementar la simulación del modelo matemático de un panel fotovoltaico S60MC.

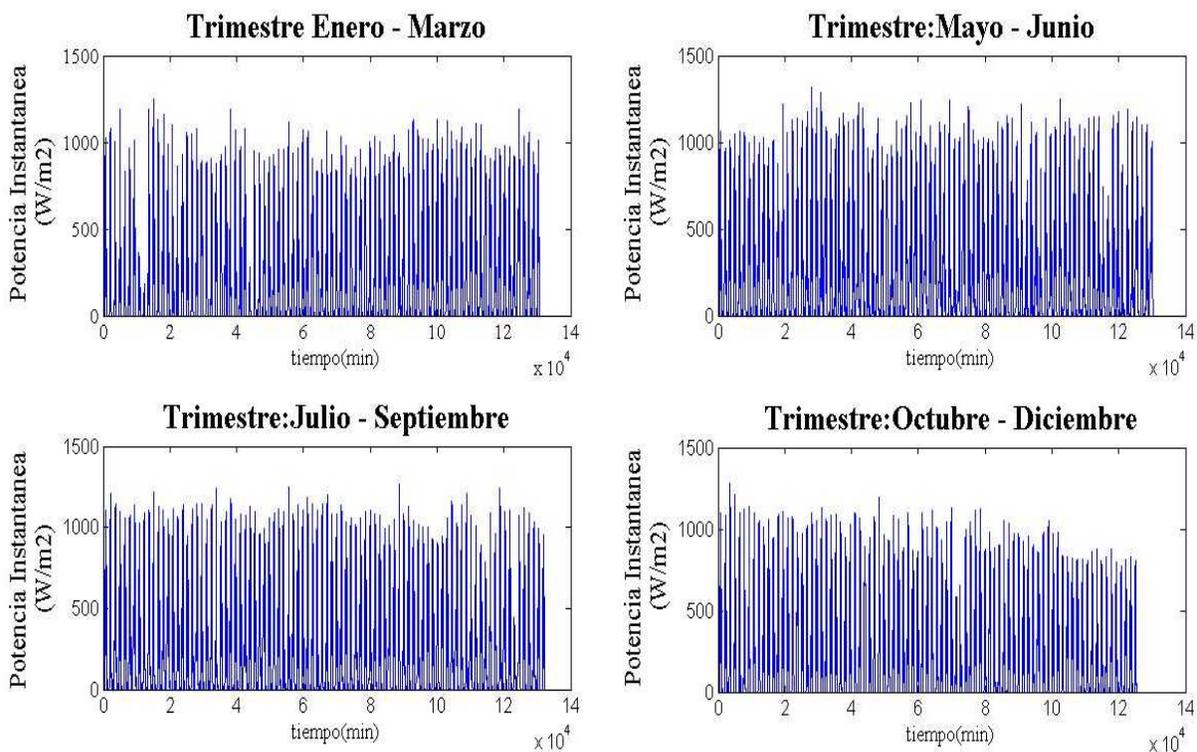


Figura 2.17.- Curvas de irradiación diaria para la ciudad de Mérida (año 2013)

Tabla 2.6.- Irradiación promedio diaria para la ciudad de Mérida (año 2013)

Mes	Irradiación promedio diario ($kW \cdot h/m^2$)
Enero	3.9147
Febrero	4.7759
Marzo	5.8352
Abril	6.1397
Mayo	5.7957
Junio	4.9753
Julio	5.4803
Agosto	5.7096
Septiembre	5.1945
Octubre	4.9861
Noviembre	4.5028
Diciembre	3.6928

Se tiene entonces una insolación para la región de

$$I_d = 5.0698 \frac{k \ h}{m^2 d}$$

La demanda del edificio de Energías Renovables de la Facultad de Ingeniería de la UADY se estimará a partir de mediciones reales tomadas durante el mes de mayor consumo energético. La figura 2.18 muestra el perfil de demanda para el mes de mayo (se eliminó el día inhábil de la serie de tiempo con fines de consistencia).

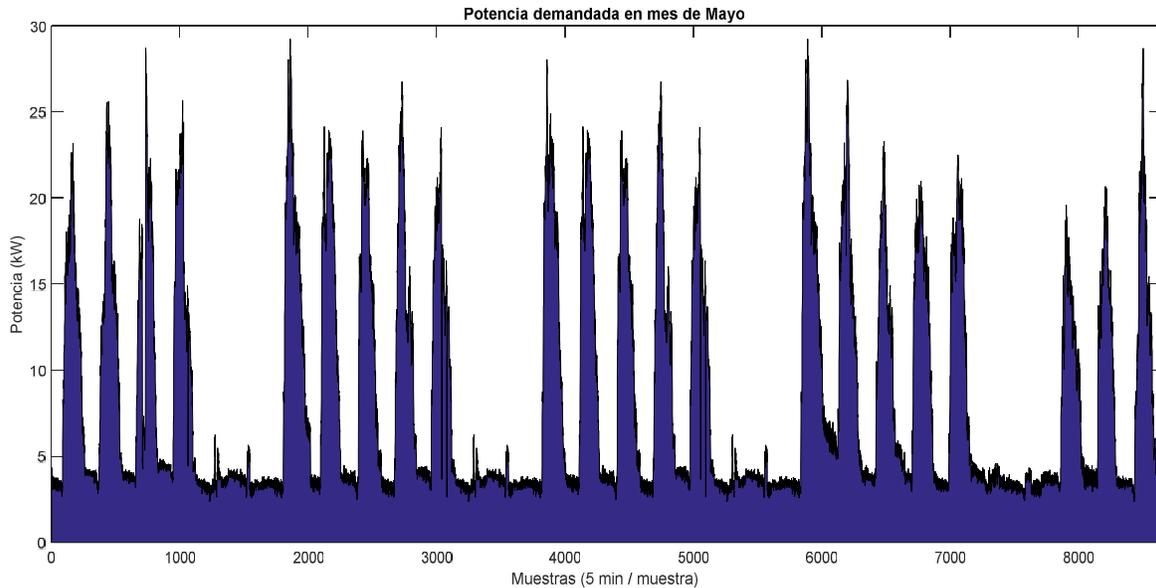


Figura 2.18.- Potencia de la carga para un mes con muestras cada 5 minutos.

A partir de las mediciones del mes de mayor consumo energético se puede obtener una estimación de la carga energética mensual. Se integra numéricamente la curva de potencia $P(t)$ mostrada en la figura 2.19 para obtener la demanda energética por mes.

$$E_c = \left(\int P(t) dt \right) \left(\frac{1h}{12m} \right)$$

$$E_c = 6,190 \text{ k h / m}$$

Para poder satisfacer esta demanda es necesario una instalación fotovoltaica capaz de generar 206.32 kWh diariamente. Al considerar la insolación promedio de $5.0698 \frac{k}{m^2 d}$ se puede calcular la potencia fotovoltaica instalada con paneles de 250 W de potencia, eficiencia de 15.9 % y un área de 1.63 m^2 como

$$P_p = \left(5.0698 \frac{k h}{m^2 d}\right) (1.63 m^2) (0.153)$$

$$P_p = 1.2644 \frac{k h}{d p}$$

De donde el número de paneles necesarios en la instalación fotovoltaica está dado por

$$\begin{aligned} \#p &= \frac{P_c}{P_p} \\ &= \frac{206.32 \frac{kWh}{d}}{1.2644 \frac{k h}{d p}} = 163.17 p \end{aligned}$$

Se requiere entonces una capacidad instalada de 40 kW de generación fotovoltaica para satisfacer la demanda energética.

Sin embargo, en la práctica, los sistemas fotovoltaicos son muy sensibles a los incrementos de temperatura lo cual deriva en una pérdida de eficiencia. Para estimar la pérdida de eficiencia en condiciones reales se tomaron mediciones de la generación de potencia en una planta fotovoltaica de 4 kW la cual es monitoreada en intervalos de 5 min.

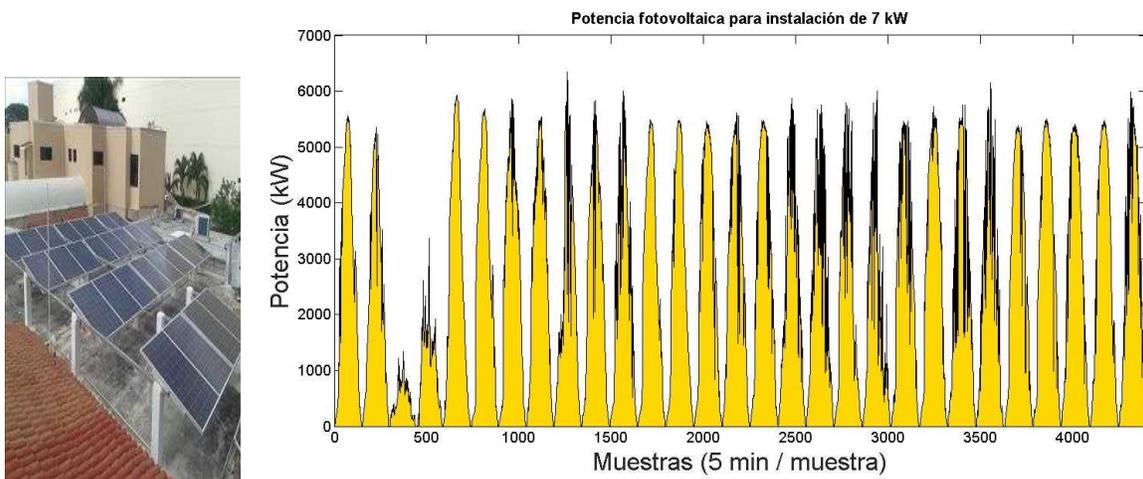


Figura 2.19.- Potencia fotovoltaica generada para mes de abril en una instalación de 7 kW

En condiciones normales de operación, bajo una insolación de 6.1397 kWh/m^2 correspondiente al mes de abril, la planta fotovoltaica debería producir

$$E_p = \left(6.1397 \frac{\text{kWh}}{\text{m}^2 \text{d}}\right) \left(1.63 \frac{\text{m}^2}{\text{p}}\right) (0.153)(28 \text{ p}) (30 \text{ d})$$

$$E_p = 1286.19 \text{ kWh}$$

A partir del análisis de los datos medidos de la instalación de 7 kW, se tiene que se generaron en los 30 días de abril, 939.82 kWh. Los efectos de temperatura producen en este caso una caída en la producción de un 27% a pesar de ser el mes de mayor potencial solar. En general los paneles poseen un coeficiente de pérdida de eficiencia de $0.5\%/^{\circ}\text{C}$. Durante los meses de mayor radiación y sensación térmica, los módulos fotovoltaicos pueden alcanzar hasta los 70°C derivando en una pérdida de eficiencia de alrededor del 20%.

Para comparar el fenómeno de pérdida de eficiencia en los módulos fotovoltaicos entre meses alta y baja radiación, se analizó una muestra de la potencia generada por la instalación de 7 kW en el mes de febrero. La irradiancia promedio diaria es de 4.509 kWh/m^2 y la generación fotovoltaica promedio diaria es de 28.15 kWh . La generación fotovoltaica diaria teórica para estas condiciones es de

$$E_p = \left(4.509 \frac{\text{kWh}}{\text{m}^2 \text{d}}\right) \left(1.63 \frac{\text{m}^2}{\text{p}}\right) (0.153)(28 \text{ p})$$

$$E_p = 31.48 \text{ kWh}$$

En este caso se tiene una pérdida de generación del 10 %, de donde es evidente la influencia de las condiciones climatológicas en la eficiencia de la instalación fotovoltaica. A partir de estas mediciones puede concluirse que a pesar de que los meses de diciembre a febrero son considerados de baja radiación, la disminución en la generación de energía no es tan significativa como la que se presenta en los meses de mayor irradiancia.

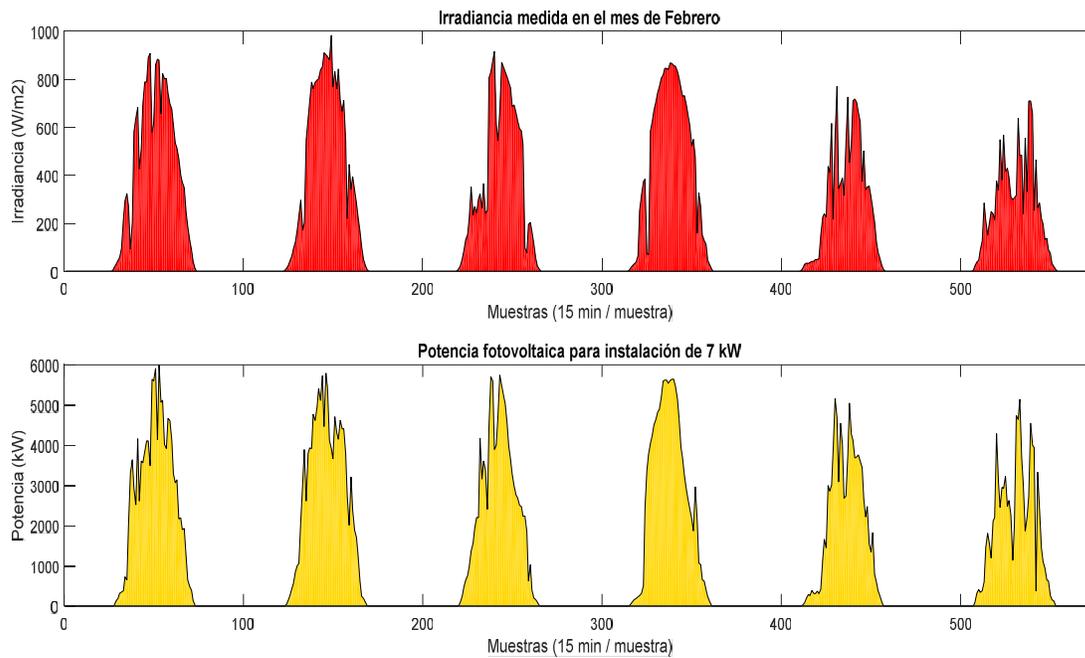


Figura 2.20. Potencia fotovoltaica generada para mes de febrero en una instalación de 7 kW

Finalmente, para poder satisfacer la demanda energética tomando en cuenta las posibles pérdidas por calentamiento se propone incrementar en un 10% la capacidad instalada, siendo el diseño final de la generación fotovoltaica de 44 kW, el doble de la instalación existente actualmente. Se requiere para esto, 176 paneles de 250 W, los cuales se pueden conectar a 4 inversores Fronius de 11.4 kW.

2.7.- Dimensionamiento del electrolizador y celda de combustible

A partir del modelo presentado con anterioridad, es posible estimar la producción de hidrógeno por parte del electrolizador a partir de la predicción de la red neuronal para la generación fotovoltaica. La predicción del almacenamiento en hidruros metálicos permitirá determinar el dimensionamiento del sistema de producción de hidrógeno y la celda de combustible.

Para este proyecto se propone utilizar el modelo desarrollado en el capítulo 2, con los parámetros presentados en [38] para un electrolizador de 26 kW. 7 bar y el cual opera en un intervalo de 30-40 V lo cual es adecuado para aplicaciones fotovoltaicas. Un modelo comercial con características similares es el McLyzer-8 bar de 31 kW, el cual es capaz de producir 6 Nm³/h.

Para la estimación de la cantidad de hidrógeno generado se utiliza la predicción de la red neuronal de la generación de potencia por parte de la planta fotovoltaica. La figura 2.21 muestra el diagrama en Simulink para la predicción de producción de hidrógeno por el electrolizador.

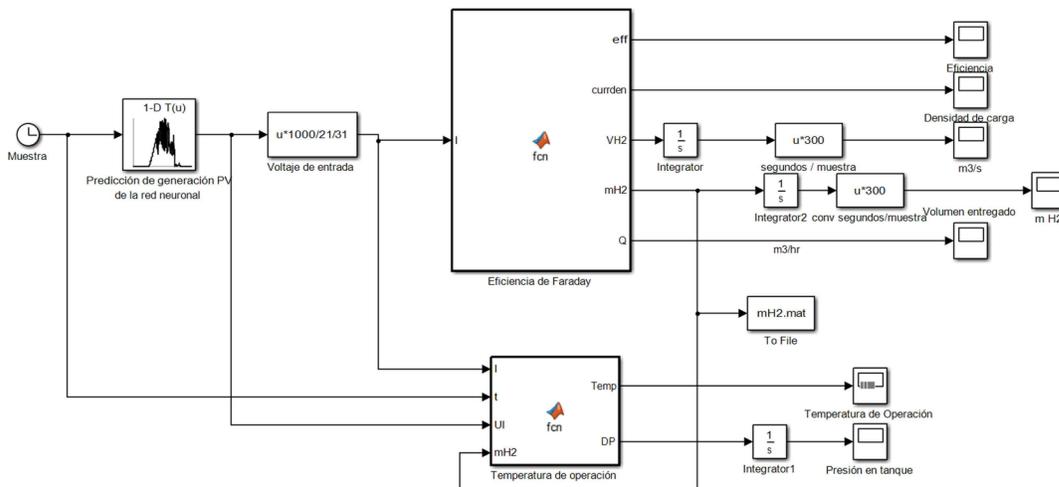


Figura 2.21.- Modelo en Simulink de electrolizador de 26 kW

2.8 Aproximación de funciones mediante redes neuronales de alto orden

Una de las principales aplicaciones de las redes neuronales artificiales es la aproximación de funciones no lineales [25]. Para la aproximación de funciones con un número de variables pequeño, una red de alto orden se construye utilizando el producto directo de funciones de activación unidimensionales. La estructura propuesta es una red compuesta por un vector de entrada, una capa oculta y una capa de salida como se muestra en la Figura 2.22. La capa de entrada está compuesta de las entradas externas a la red, las mediciones actuales y pasadas de la variable a aproximar y las salidas pasadas de la red. La capa oculta es donde se realiza principalmente el procesamiento de la información y

está compuesta de A unidades de procesamiento las cuales se alimentan del vector de la capa de entrada ponderados por los pesos sinápticos. La capa de salida es el conjunto de neuronas que se alimentan de las salidas de la capa oculta y su salida es la respuesta de la red neuronal al estímulo del vector de entrada.

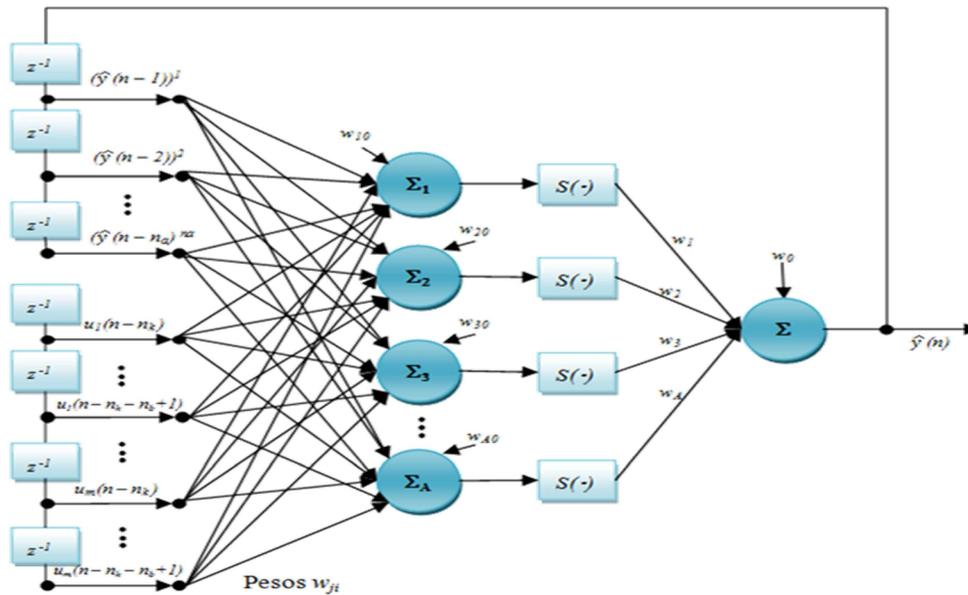


Figura 2.22.- Estructura de Red alto orden

Una red recurrente es aquella que incluye en sus entradas retroalimentación de salidas anteriores y además responde temporalmente a una señal de entrada externa. La retroalimentación permite a la red neuronal tener una representación en uno modelo dinámico en espacio de estados, lo que es conveniente para diversas aplicaciones, como modelado, predicción, identificación y control.

El modelo matemático de la salida de y_k de la neurona k , donde $k=1, \dots, A$, donde A es el número de neuronas en la capa oculta y con p conexiones, como se muestra en la figura 2.22, está dado por

$$y_k = \varphi \left(\sum_{j=1}^p w_k x_j - \theta_k \right)$$

donde x_j es la entrada j a la neurona, w_k es el peso que conecta la entrada j a la neurona k , θ_k es el parámetro de bias y $\sum_{j=1}^p w_k x_j$ es el potencial de activación. El orden de la red se refiere a la forma en la que se define el potencial de activación [25]. Cuando el potencial de activación se combina con productos de las señales retroalimentadas y las entradas se tiene una red de orden r , donde r representa el número de señales multiplicadas. El término orden superior se emplea cuando la entrada a una neurona incluye el producto de más de dos señales.

Considerando el modelo de una red neuronal recurrente de alto orden, donde los términos de alto orden incluyen productos y potencias de la función de activación [25]:

$$\hat{x}_i(k+1) = w_i^T z(\hat{x}(k), u(k)) \quad i=1, \dots, A \quad (77)$$

donde $\hat{x}_i(k)$ es el estado de la i -ésima neurona en la iteración k , w_i es el i -ésimo vector de pesos adaptables de la red neuronal, $u(k) = [u_1, u_2, \dots, u_m]^T \in R^m$ es el vector entradas externas a la red neuronal y $z(\hat{x}(k), u(k))$ es el vector de funciones de activación definido por

$$z(\hat{x}(k), u(k)) = [z_1, z_2, \dots, z_L]^T = \left[\prod_{j \in I_1} \langle_j^{d_j(1)}, \prod_{j \in I_2} \langle_j^{d_j(2)}, \dots, \prod_{j \in I_L} \langle_j^{d_j(L)} \right]^T \quad (78)$$

$$\langle = [\langle_1, \dots, \langle_A, \langle_{A+1}, \dots, \langle_{A+m}]^T = [S(x_1), \dots, S(x_A), S(u_1), \dots, S(u_m)]^T \quad (79)$$

donde L es el número de conexiones de alto orden, $\{I_1, I_2, \dots, I_L\}$ es una colección de subconjuntos no ordenados de $\{1, 2, \dots, A+m\}$, A es la dimensión de ésta, $d_j(l)$ representa enteros no negativos, es un vector construido por las entradas a cada neurona y $S(\cdot)$ es la función sigmoide dada por:

$$S(\hat{x}(k)) = \frac{1}{1 + \exp(-a\hat{x}(k))} \quad (80)$$

Para la función sigmoide, es una constante positiva. A partir de la estructura de la ecuación (77) se derivan tres modelos

Modelo paralelo

$$\hat{x}_i(k+1) = w_i^T z(\hat{x}(k), u(k)) \quad i = 1, \dots, A \quad (81)$$

donde el estado de la red $\hat{x}(k+1)$ depende solamente del estado anterior $\hat{x}(k)$, entradas pasadas a la red y los pesos adaptables.

Modelo serie-paralelo

$$\hat{x}_i(k+1) = w_i^T z(x(k), u(k)) \quad i = 1, \dots, A \quad (82)$$

donde el estado de la red $\hat{x}(k+1)$ depende del estado anterior $\hat{x}(k)$ de la red y el estado $x(k)$ del sistema a identificar, entradas pasadas a la red y los pesos adaptables.

Modelo prealimentado, de alto orden (HONN).

$$\hat{x}_i(k+1) = w_i^T z(u(k)) \quad i = 1, \dots, A \quad (83)$$

donde el estado de la red $\hat{x}(k+1)$ depende del estado anterior $\hat{x}(k)$ de la red, los pesos adaptables y el vector sigmoide contiene términos de alto orden en entradas pasadas como se define en las ecuaciones 78-81.

Para la aplicación de la red neuronal recurrente en aproximación de funciones se consideran dos capas de neuronas una capa oculta y una de salida. En la capa oculta (con A unidades) utilizan una función de activación sigmoide logística a su salida definida como:

$$S(\xi) = \frac{1}{1 + \exp(-\xi)} \quad \xi > 0 \quad (84)$$

donde ξ es cualquier valor real. La capa de salida de esta red está compuesta de una única neurona con función de activación lineal y puede ser representada mediante:

$$\hat{y}(k) = \sum_{i=0}^A w_i(k) y_i(k) \quad (85)$$

donde $y_l(k)$ es la salida de la neuronal a través de la función de activación sigmoide logística.

2.8.1.- Entrenamiento por el filtro extendido de Kalman

Con los dos conjuntos de pesos, localizados entre la capa oculta de entrada y la capa de salida, se construyó un vector de pesos que fue ajustado mediante un entrenamiento basado en 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 en sistemas no lineales.

Se define un sistema dinámico no lineal descrito por el siguiente modelo en espacio de estados:

$$w(k+1) = F_{k+1,k} w(k) + \hat{v}_1(k) \quad (86)$$

$$y(k) = H(k)w(k) + \hat{v}_2(k) \quad (87)$$

La ecuación (86) 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 $\hat{v}_1(k)$ es el ruido en el proceso. Por otra parte, la ecuación (87) 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 $\hat{v}_2(k)$ es el ruido en la medición. El ruido en la medición $\hat{v}_2(k)$ es ruido independiente, blanco, gaussiano, con media cero y con matriz de covarianza $E[\hat{v}_2(l) \hat{v}_2^T(l)] = \sigma_k, I_Q(k)$. Similarmente, el ruido del proceso $\hat{v}_1(k)$ está también caracterizado como ruido independiente, blanco, gaussiano y con matriz de covarianza $E[\hat{v}_1(l) \hat{v}_1^T(l)] = \sigma_k, I_R(k)$. 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

$$K(k) = P(k)H^T(k)[R + H(k)P(k)H^T(k)]^{-1} \quad (88)$$

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

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

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; o 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:

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

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

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

2.8.2.- Estructura del vector regresor de la red neuronal

Un aspecto importante en la predicción del comportamiento de una variable mediante redes neuronales artificiales es la elección de un número adecuado de señales retardadas, las cuales, junto con las entradas externas, se utilizarán en la fase de entrenamiento, constituyendo el vector regresor. La selección de un número incorrecto de señales retardadas, que se utiliza como regresores, podría tener un impacto sustancialmente negativo en el proceso de entrenamiento, mientras que un número demasiado pequeño implica que aspectos esenciales de la dinámica pueden ser no

modelados. Además, un gran número de términos en el vector regresor aumenta el tiempo de cómputo requerido para la convergencia del algoritmo pudiendo además contener información redundante. Para un buen comportamiento de la estructura del modelo, es necesario tener tanto un vector regresor suficientemente grande y un número adecuado de unidades ocultas en la capa de procesamiento. Si el espacio de retardo se determina correctamente, el problema de selección de la estructura del modelo se reduce sustancialmente.

Ha habido mucha investigación en torno a cómo determinar la dimensión óptima de una serie de tiempo escalar con base en el Teorema de Takens [37]. Los métodos básicos, que por lo general se utilizan para elegir la dimensión mínima de la serie de tiempo, son los siguientes: (1) el cálculo de invariantes en el atractor, (2) la descomposición de valor singular y (3) el método de falsos vecinos. Sin embargo, un método práctico para seleccionar el espacio es el propuesto por [38] 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. En este trabajo, se adopta esta técnica para la determinación de la estructura óptima del vector regresor.

Consideremos una serie de tiempo constituida por la secuencia de mediciones x_1, x_2, \dots, x_n y definamos un conjunto de vectores de retardo en el tiempo

$$y_i = [x_i, x_{i+\dagger}, \dots, x_{i+(d-1)\dagger}] \quad (89)$$

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

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

$$E(d) = \frac{1}{N - d\dagger} \sum_{i=1}^{N-d\dagger} \frac{\|y_i(d+1) - y_{n(i,d)}(d+1)\|}{\|y_i(d) - y_{n(i,d)}(d)\|} \quad (90)$$

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

donde $n(i, d)$ es un entero tal que $y_{n(i,d)}(d)$ es el vecino más cercano de $y_i(d)$. La mínima dimensión embebida d_0 , $E(d)$ deja de cambiar para una d_0 [38].

2.9 Gestión energética de la microred eléctrica inteligente.

En esta sección se desarrolla la solución al problema de optimización de la operación de una micro red de energía eléctrica interconectada a un bus de CD; la fuente de generación de potencia proviene de un arreglo de paneles fotovoltaicos, como método de almacenamiento se considera un electrolizador para generación de hidrógeno y como fuente auxiliar una celda de combustible y un supercapacitor como respaldo ante caídas de tensión.

El objetivo es determinar las cantidades óptimas de energía para los sistemas de celda de combustible, fotovoltaico y supercapacitor, buscando satisfacer la demanda. Se propone un esquema que minimiza los costos de operación de las fuentes de energía.

El problema de optimización, de la función de balance energético de la microred, a resolver es del tipo de programación lineal, y para su solución, inicialmente se emplea la red neuronal descrita en [7] realizando los ajustes necesarios al problema de programación lineal original obtenido del esquema propuesto al prototipo mencionado. Se propone una red neuronal recurrente capaz de resolver el problema de optimización original y se diseñan los programas computacionales para simular la operación óptima de la microred, empleando redes neuronales de alto orden para la predicción de generación fotovoltaica y una red dinámica para la solución del problema de optimización. Los resultados de simulación muestran el desempeño de tales redes neuronales. Para resolver el problema de optimización es necesario definir los costos de operación de cada fuente de energía que conforma la microred.

2.9.1.- Descripción del problema de gestión energética.

El esquema del SHGE a analizar se muestra en la Fig. 2.23. Se compone de un bus de CD, un sistema fotovoltaico, celda de combustible y un supercapacitor. El objetivo del problema de optimización de la operación del SHGE es determinar las cantidades óptimas de potencia para cada fuente de energía, para satisfacer la demanda eléctrica, respecto a un horizonte de tiempo. Para optimizar la operación de la micro-red eléctrica, el horizonte de tiempo se divide en T intervalos, como se muestra a continuación:

$$CT = \sum_{t=1}^T FC(P_{SG,t}) \quad (91)$$

El problema de gestión energética de la función descrita en la ecuación (91) busca el minimizar el consumo energético de las cargas de la red, que pueden ser críticas u ordinarias, y los costos de operación del SHGE; la función objetivo se plantea de la siguiente manera:

Minimizar: (92)

$$FC(t) = C_G P_G(t) + C_{PV} P_{PV}(t) + C_{FC} P_{FC}(t) + C_{SCC} P_{SCC}(t) + C_{SCD} P_{SCD}(t) + C_{EL} P_{EL}(t)$$

donde:

$P_{BD}(t)$	Potencia de descarga de la celda de combustible
$P_{BC}(t)$	Potencia consumida por electrolizador
C_G	Costo de la potencia suministrada por el bus de CD en \$/kW
C_{PV}	Costo de la potencia fotovoltaica en \$/kW
C_{FC}	Costo de la potencia de la celda de combustible en \$/kW
C_{SCC}	Costo de la potencia de carga del supercapacitor en \$/kW.
C_{SCD}	Costo de la potencia de descarga por el supercapacitor en \$/kW
C_{EL}	Costo de la potencia consumida por electrolizador en \$/kW

El problema de optimización se encuentra sujeto a restricciones, las cuales también se definen en cada subsistema que componen la micro-red eléctrica como se muestra:

Ecuación de balance de potencia:

$$P_{PV,t}(t) + P_{FC,t}(t) \pm P_{SC,t} = L_{C,t}(t) + L_{O,t}(t) \quad (93)$$

donde:

$L_C(t)$	Demanda de potencia crítica
$L_O(t)$	Demanda de potencia ordinaria

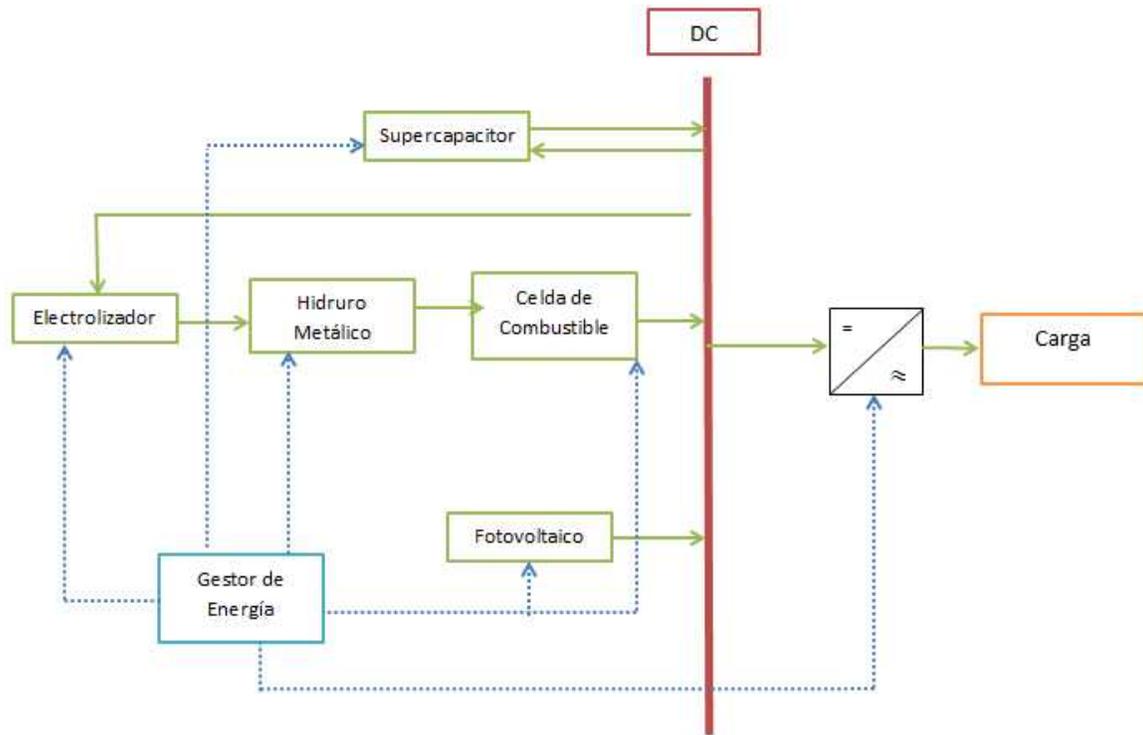


Figura 2.23.- Esquema del prototipo del SHGE a analizar

Las restricciones de la microrred dependen de los valores máximos y mínimos de potencia que la red de energía del bus CD puede suministrar en un intervalo de tiempo.

P_{FCMax}	Potencia de la celda de combustible máxima
P_{FCMin}	Potencia de la celda de combustible mínima
P_{PVMax}	Potencia fotovoltaica máxima
P_{PVMin}	Potencia fotovoltaica mínima
P_{GMax}	Potencia máxima a descargar de cargas ordinarias del bus de CD
P_{GMin}	Potencia mínima a descargar de cargas ordinarias del bus de CD
P_{SCCMax}, P_{SCDMax}	Potencia máxima del supercapacitor en carga y descarga
P_{SCCMin}, P_{SCDMin}	Potencia mínima del supercapacitor en carga y descarga
P_{CL}	Demanda de potencia crítica
P_{OL}	Demanda de potencia ordinaria

2.9.2 Redes neuronales dinámicas para programación lineal.

El objetivo de resolver un problema de optimización es determinar los valores de las variables de decisión que maximizan ó minimizan una función objetivo definida y sujeta a diferentes restricciones. En muchos sistemas de tiempo real, tales como redes de energía interconectadas masivamente, requieren resolver problemas de programación lineal a gran escala en tiempo real. En tales aplicaciones, los algoritmos secuenciales existentes, como el método simplex ó los métodos de punto interior, son usualmente ineficientes debido a la limitación de su procesamiento secuencial [7]. En general, los algoritmos tradicionales pueden ser ineficientes ya que el tiempo de cálculo requerido para una solución, depende mucho de la dimensión y estructura de los problemas planteados. Un posible y muy prometedor enfoque, para la optimización en tiempo real, es aplicar redes neuronales artificiales; debido a su paralelismo masivo, el enfoque de redes neuronales puede resolver problemas de optimización de gran magnitud en tiempo real más rápido que los algoritmos de optimización más populares ejecutados en computadoras digitales de propósito general. A continuación, se presenta el problema de programación lineal general con restricciones como se muestra en [39]:

Minimizar

$$f(v) = c^T v \quad (94)$$

Sujeto a

$$Av = b, \\ 0 \leq v_i \leq v_{\max}$$

$$c \in \mathbb{R}^n, v \in \mathbb{R}^n, A \in \mathbb{R}^m, b \in \mathbb{R}^m, l \in \mathbb{R}^n, q \in \mathbb{R}^n \quad (95)$$

donde v es el vector de variables de decisión, c es el vector de coeficientes de costo, b es el vector de parámetros de lado derecho y A es la matriz de coeficientes de restricción.

Para resolver el problema de optimización, se propone la siguiente red neuronal recurrente que consiste de n neuronas artificiales conectadas masivamente.

$$\dot{u}(t) = -\alpha A^T A (t) + \alpha A^T b - \beta e^{-\eta} c \quad (96)$$

$$c \in \mathbb{R}^n, v \in \mathbb{R}^n, A \in \mathbb{R}^m, b \in \mathbb{R}^m, l \in \mathbb{R}^n, q \in \mathbb{R}^n$$

$$v_i(t) = \begin{cases} l_i & \text{si } u_i(t) < l_i \\ q_i & \text{si } u_i(t) > q_i \\ u_i(t) & \text{de otra forma,} \end{cases} \quad (97)$$

$i = 1, 2, \dots, n; u \in \mathbb{R}^n; \alpha, \beta, \eta \in \mathbb{R} > 0.$

Cada ecuación diferencial, para una variable de decisión v_i , es considerada una neurona dinámica, utilizando una estructura basada en el modelo de Hopfield [25],[38]. En las ecuaciones de estado de la nueva red neuronal recurrente $u(t)$ es un vector columna n dimensional de entradas instantáneas a la red a las neuronas, $v(t)$ es un vector columna n dimensional de estados de activación que corresponden al vector de variables de decisión, $u(0), v(0)$ son especificadas a priori. La ecuación (96) define la dinámica de la red neuronal, en la cual los primeros dos términos en el lado derecho cumplen la restricción de igualdad (94) y (95) y el tercer término ayuda a minimizar la función objetivo. La ecuación (97) define las funciones de activación para cumplir la restricción (95). Los valores mínimos y máximos para el vector de las variables de decisión v se definen en los vectores l y q respectivamente, el espacio de estado de la red neuronal recurrente se define como un hiper-paralelogramo rectángulo $v = [l, q], \therefore \hat{V} \subseteq V$. La estabilidad del modelo dinámico de la red neuronal, es tratada en [7] y [39].

2.10 Metodología de integración de la microred

La fiabilidad es uno de los factores más importantes en la operación de redes eléctricas inteligentes, por lo que la vigilancia y el control constante es necesario para alcanzar este objetivo. Un pronóstico preciso de la generación fotovoltaica y demanda energética puede mejorar el rendimiento de los controladores inteligentes y sistemas de gestión en la red.

Debido a las variaciones aleatorias en las condiciones climáticas, la producción de energía a partir de fuentes renovables está en constante cambio. La combinación de la predicción de la radiación solar, temperatura del módulo y de la potencia de salida es una buena manera de mejorar el rendimiento en la programación de la energía fotovoltaica.

Una vez que cada uno de los elementos de la microred ha sido modelado mediante métodos matemáticos adecuados, se procedió a integrarlos en un entorno de simulación.

La microred propuesta fue diseñada en la topología en paralelo con acoplamiento en CD mostrada en la sección 1.6.3. Para el modelo de sistema fotovoltaico se utilizó el modelo presentado en la sección 2.1; a partir de este modelo se generó una base de datos de las curvas I-V y curvas de potencia para diferentes niveles de radiación y temperatura; esta base de datos fue utilizada para entrenar una red neuronal y obtener una aproximación del modelo de generación de potencia. Para la celda de combustible y el electrolizador se utilizaron los modelos descritos en las secciones 2.2 y 2.3; estos modelos utilizarán como entrada la generación de potencia proveniente de las predicciones de generación fotovoltaica, realizadas por la red neuronal recurrente descrita en la sección 2.8. El resultado del modelo electrolizador-celda de combustible será la generación de potencia de respaldo de la microred la cual opera soportada por el banco de supercapacitores ante variaciones de voltaje y cuyo modelo es descrito en la sección 2.4. Finalmente, el flujo energético de la microred fue determinado por la solución del problema de programación lineal obtenido por la red neuronal dinámica descrita en la sección 2.9, cuyo resultado determina la predicción del uso energético y la posible descarga de cargas ordinarias en caso de no poder satisfacer la demanda. La simulación de la microred integra los modelos matemáticos, modelos de predicción y modelo de gestión energética. Los resultados de estos modelos son presentados en el Capítulo 3.

CAPÍTULO 3.

RESULTADOS

3.1 Caracterización de las curvas de potencia de los paneles fotovoltaicos y celda de combustible utilizando redes neuronales de alto orden.

Se diseñó una red neuronal multicapa con 10 neuronas en la capa oculta, 1 en la capa de salida. Para validar con el mayor número de datos posibles de las curvas I-V, los datos para entrenar la red se tomaron de un simulador con los datos de fábrica del modelo comercial S60MC. Se tomaron como datos de entrenamientos de la red, los datos obtenidos del simulador descrito en el capítulo 2. Las variables de entrada a la red fueron: Irradiación (W / m^2), Temperatura (K), Voltaje (V) y la salida de la red es la estimación de la corriente (A).

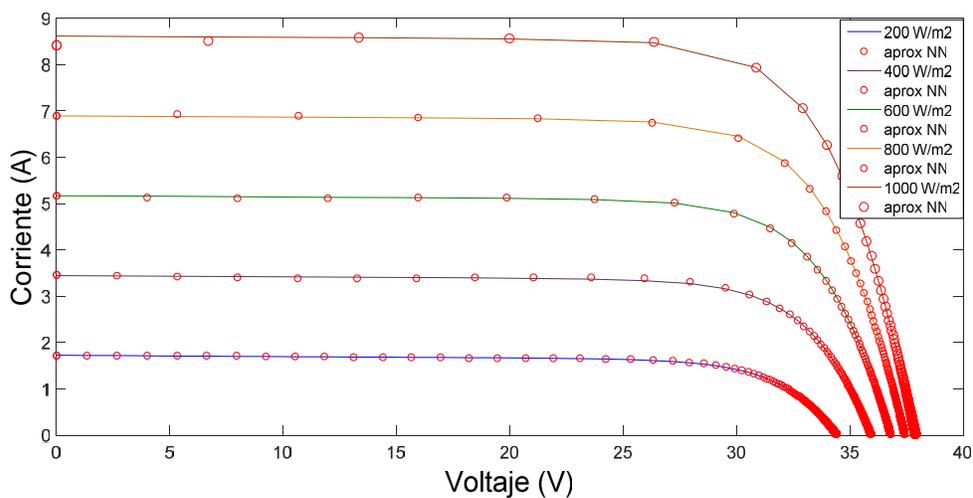


Figura 3.1.- Aproximación de Curva I-V a 25° mediante red neuronal para diferentes niveles de irradiancia.

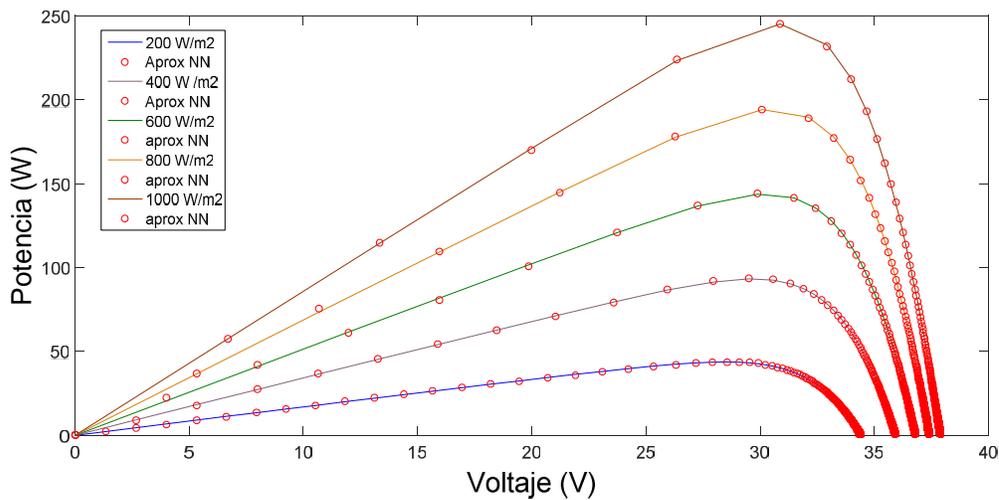


Figura 3.2.- Aproximación de Curva de Potencia a 25°C mediante red neuronal para diferentes niveles de irradiancia.

Para aproximar la curva Voltaje-Potencia, se diseña una red neuronal multicapa con 10 neuronas en la capa oculta, 1 en la capa de salida y un algoritmo de entrenamiento por gradiente descendiente.

Los datos para entrenar la red se tomaron de un simulador con los datos de fábrica del modelo comercial S60MC de 5 niveles de radiación ($200-1000 W / m^2$), y 10 niveles de temperatura (25-70 °C) para un total de 100,000 datos.

Los modelos generados por redes neuronales presentan una excelente aproximación a los valores reales. Después de un entrenamiento de 200 épocas, donde cada época es una evaluación de una serie de tiempo, la red neuronal alcanzó un error cuadrático medio $MSE=5.49 \times 10^{-6}$, el cual es un valor muy bueno para una predicción de curvas características en módulos fotovoltaicos, ya que algunos resultados en la literatura reportan MSE de 10^{-2} [41]. Para la curva de potencia, la red neuronal empleó 1600 épocas para alcanzar un $MSE=4.47 \times 10^{-5}$. La evolución de la medida del desempeño a través de las épocas, para cada entrenamiento, se muestra en las Figuras 3.3 y 3.4. En estas figuras se muestra el error cuadrático medio de la red ante los datos de entrenamiento y ante los datos de prueba. Evidentemente el error es ligeramente mayor

en la etapa de prueba, ya que los datos utilizados en la prueba son diferentes utilizados en el entrenamiento.

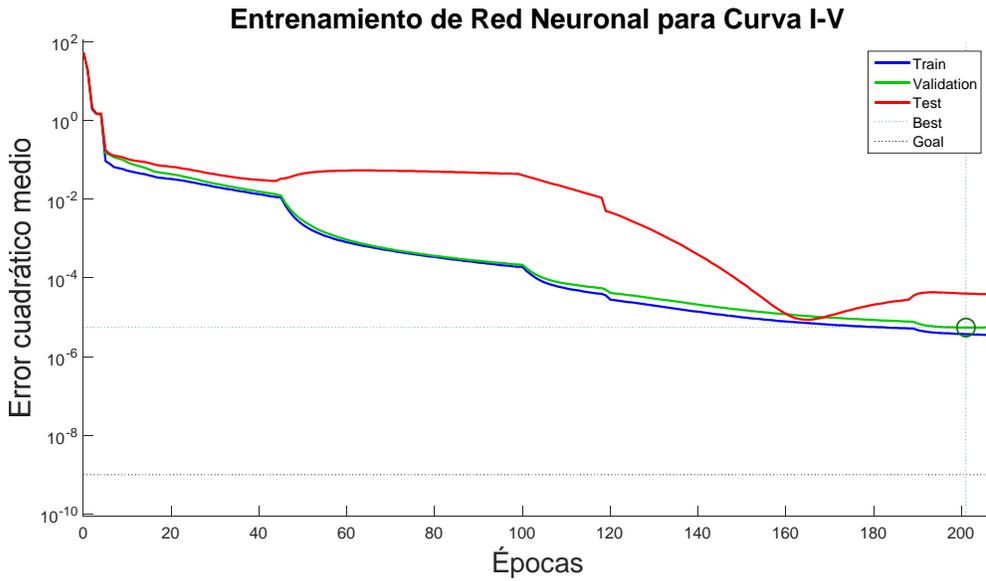


Figura 3.3.- Medida de desempeño de la red neuronal para aproximación de la curva I-V.

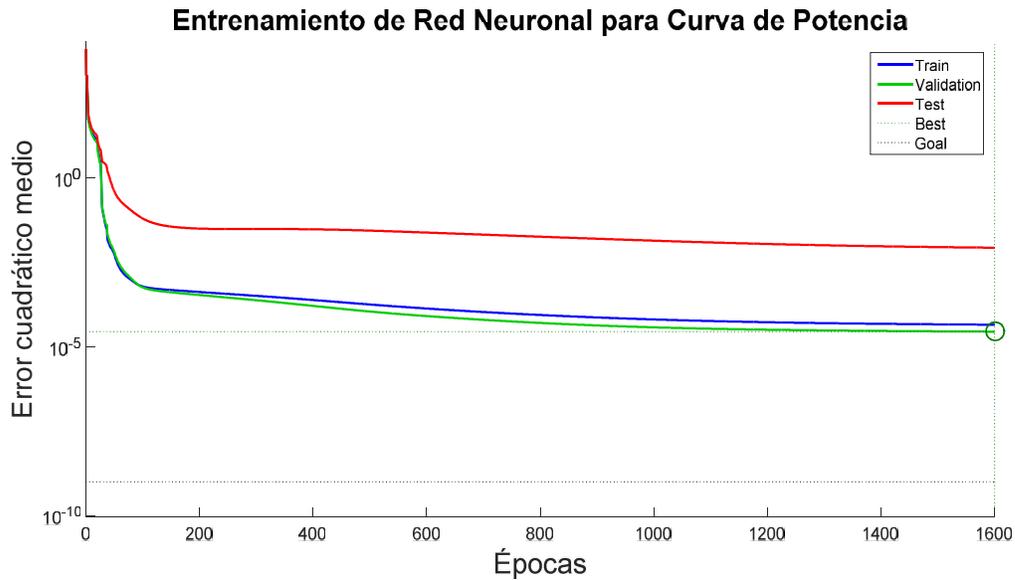


Figura 3.4.- Medida de desempeño de la red neuronal para aproximación de la curva de potencia

3.2 Predicción de la generación fotovoltaica

Para fines de simulación de la microred se consideró solo las horas efectivas de irradiación tomando muestreos cada 15 minutos en un intervalo entre las 06:30 y las 19:30 horas durante un período de 15 días. La Fig. 3.5 muestra la serie de tiempo de generación de potencia por parte de la instalación fotovoltaica para un periodo de 15 días. La red neuronal utilizó para su entrenamiento una serie de tiempo de 780 datos.

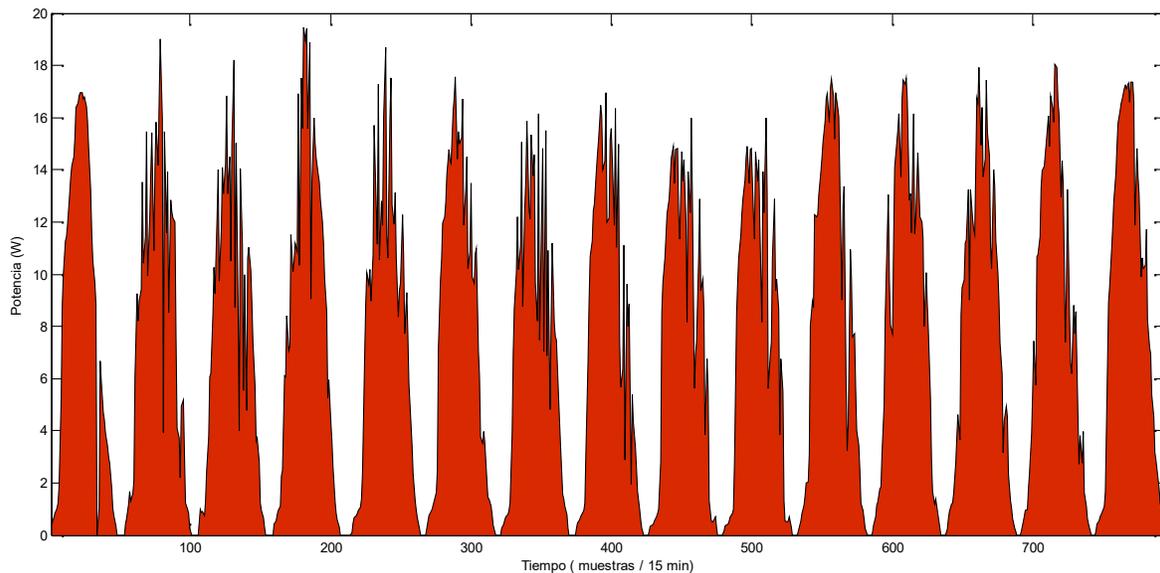


Figura 3.5.- Generación de potencia para 15 días de planta de 22 kW

Aplicamos una red neuronal de alto orden para predecir la potencia generada por el sistema fotovoltaico. Los datos meteorológicos y de generación han sido recogidos a través de los instrumentos instalados en el sistema fotovoltaico, con lecturas cada 15 minutos. Estos datos fueron sometidos al procesamiento de señales en el software Matlab para tener la serie de tiempo de las cantidades físicas de irradiación, temperatura, tensión y corriente.

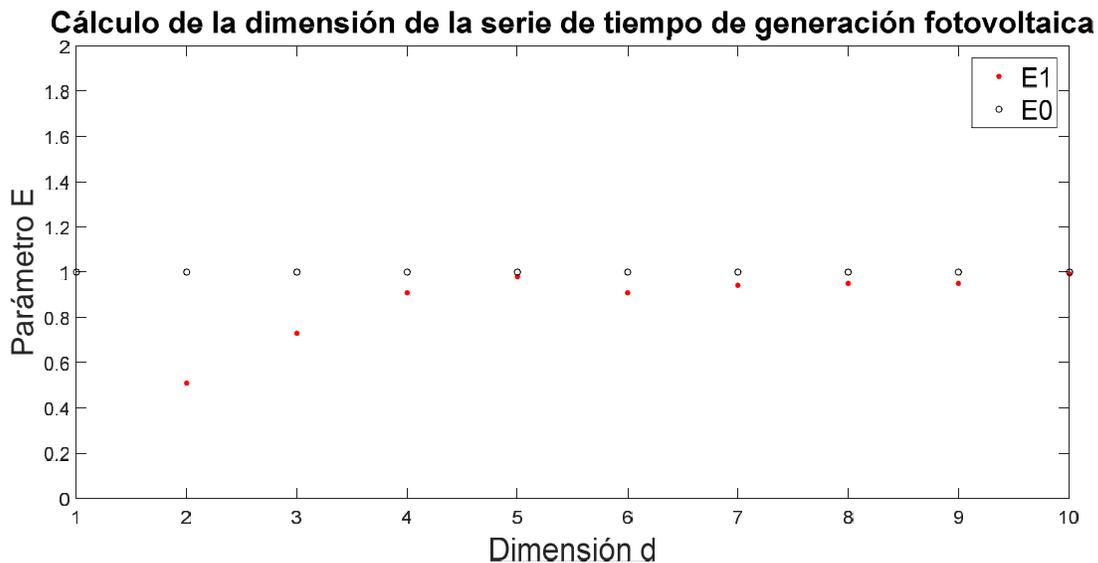


Figura 3.6.- Cálculo de la dimensión utilizando el método de Cao

Se implementa un predictor de red neuronal para la generación de energía fotovoltaica, en base al método de entrenamiento EKF. Como primera etapa se determina la dimensión óptima del vector regresor; a continuación, seleccionamos el número de unidades ocultas para ambas capas ocultas. El entrenamiento de la red se lleva a cabo utilizando los datos por 15 minutos para 15 días. La red neuronal utilizada es un perceptrón multicapa recurrente de alto orden entrenado con un EKF como el mostrado en la Figura 2.19; las funciones en la capa oculta son funciones de activación sigmoide logística, cuya se fija en 1 y la capa de salida se compone de una neurona, con una función de activación lineal. Los valores iniciales de las matrices de covarianza (R, Q, P) se determinaron aleatoriamente. Los valores iniciales para los pesos neuronales se seleccionan al azar, ya que estos evolucionarán al valor que reduce el error de aproximación independientemente de su condición inicial. La longitud del vector de regresión es 5, que se determina utilizando la metodología Cao [38]. La Figura 3.6 muestra el resultado del cálculo del coeficiente de dimensión para la serie de tiempo de la generación fotovoltaica. A partir de este resultado se selecciona una dimensión de 8 para el vector regresor. El entrenamiento se realiza fuera de línea utilizando una configuración serie paralelo; para este caso la salida retardada se toma de la generación de potencia.

Para entrenar la red neuronal de alto orden (HONN) para cada variable, seguimos los siguientes parámetros de diseño: 3 entradas externas correspondientes al módulo de irradiación, temperatura y voltaje para máxima potencia, 20 elementos en la capa oculta, 1 neurona en la capa de salida, 200 iteraciones máximo, los valores iniciales para pesos sinápticos seleccionados al azar en el rango y MSE (error cuadrático medio) necesario para poner fin al entrenamiento de menos de 1×10^{-5} .

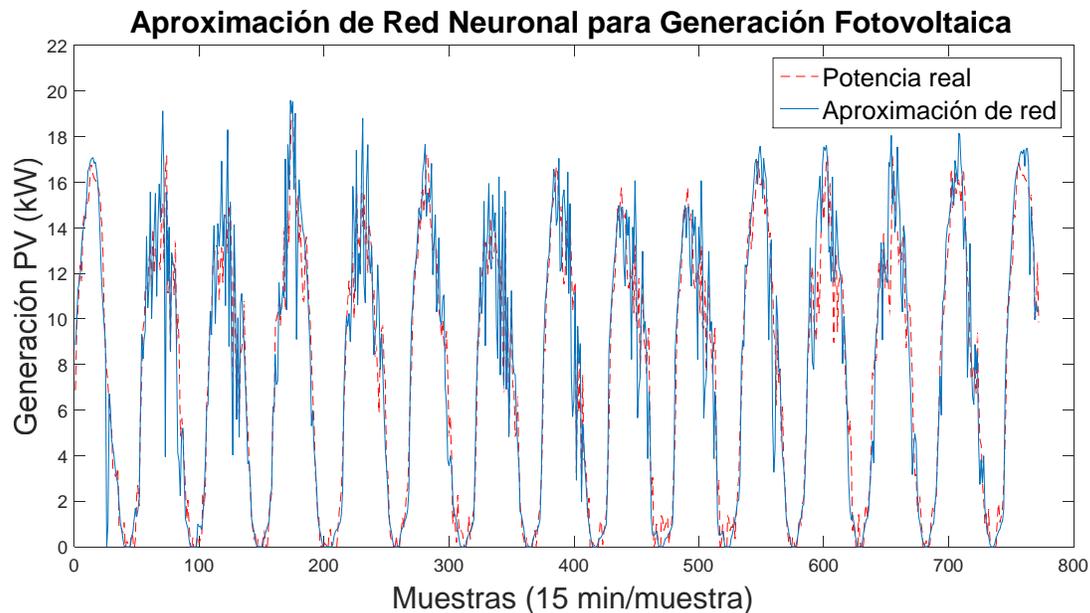


Figura 3.7.- Aproximación de la generación fotovoltaica usando redes neuronales

El resultado de la aproximación de la red neuronal para la generación de potencia del sistema fotovoltaico se muestra en la Figura 3.7, donde el entrenamiento de la red se hizo utilizando la medición de potencia para 15 días, utilizando el algoritmo de entrenamiento por el filtro extendido de Kalman. Para esta aproximación, se obtuvo un error cuadrático medio $MSE=0.004$, que es un valor bastante confiable para los fines de predicción en redes eléctricas.

Para caracterizar la operación del electrolizador consideraremos la producción fotovoltaica de un día típico junto con una curva de demanda alta. En los periodos donde la generación fotovoltaica sea mayor que la demanda, la potencia excedente será entregada al electrolizador para la producción de hidrógeno. En los periodos en los que la demanda exceda la generación fotovoltaica o está no esté disponible, se tomará la energía de la celda de combustible. En el caso en que la potencia entregada por la celda de combustible no sea suficiente para satisfacer la demanda, se tomarán acciones por parte del sistema de gestión para reducir la demanda.

Para la predicción de generación fotovoltaica, seleccionamos 8 regresores que se incluyen en el vector de entrada de la red neuronal para la medición de la serie de tiempo de la salida de potencia de la instalación. Se seleccionaron 20 neuronas en la capa oculta, 1 neurona de salida, 200 iteraciones máximo, los valores iniciales para pesos sinápticos aleatorios y un error como medida de desempeño de 1×10^{-4} . Los datos son normalizados, con respecto al valor máximo de la serie de tiempo, antes de ser procesados por la red y la salida de la red es escalada para obtener los valores reales. La figura 3.8 muestra que la predicción se realiza con éxito con un buen horizonte de predicción y un error cuadrático medio $E=0.00078$.

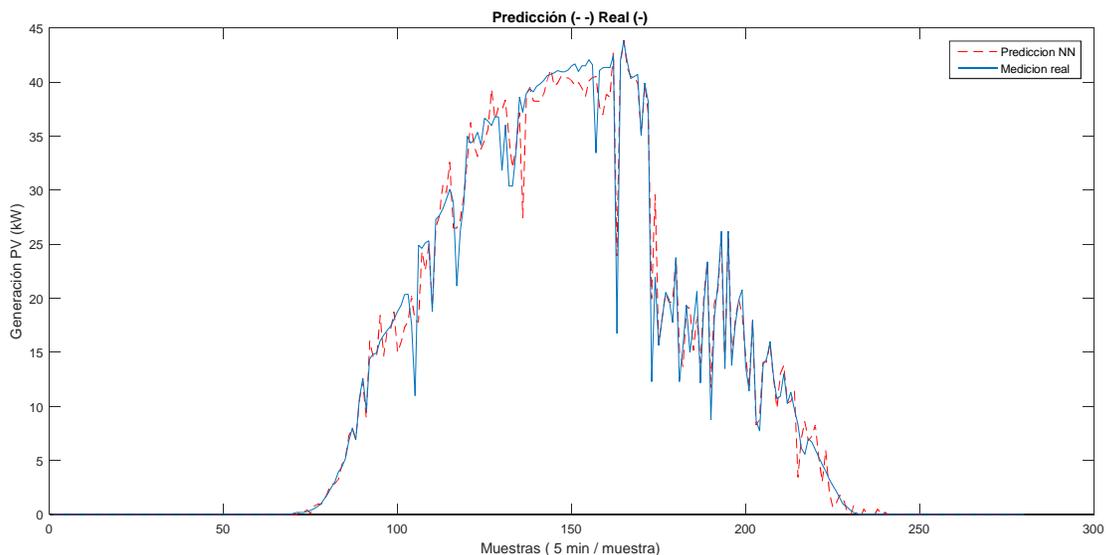


Figura 3.8.- Predicción de la generación fotovoltaica para 24 horas

Para la predicción de demanda energética, seleccionamos 8 regresores, 20 neuronas en la capa oculta, 1 neurona de salida, 150 iteraciones máximo, los valores iniciales para pesos sinápticos aleatorios y un error como medida de desempeño de 1×10^{-4} . La figura 3.9 muestra que la predicción se realiza con éxito con un buen horizonte de predicción y un error cuadrático medio $E=0.00012$.

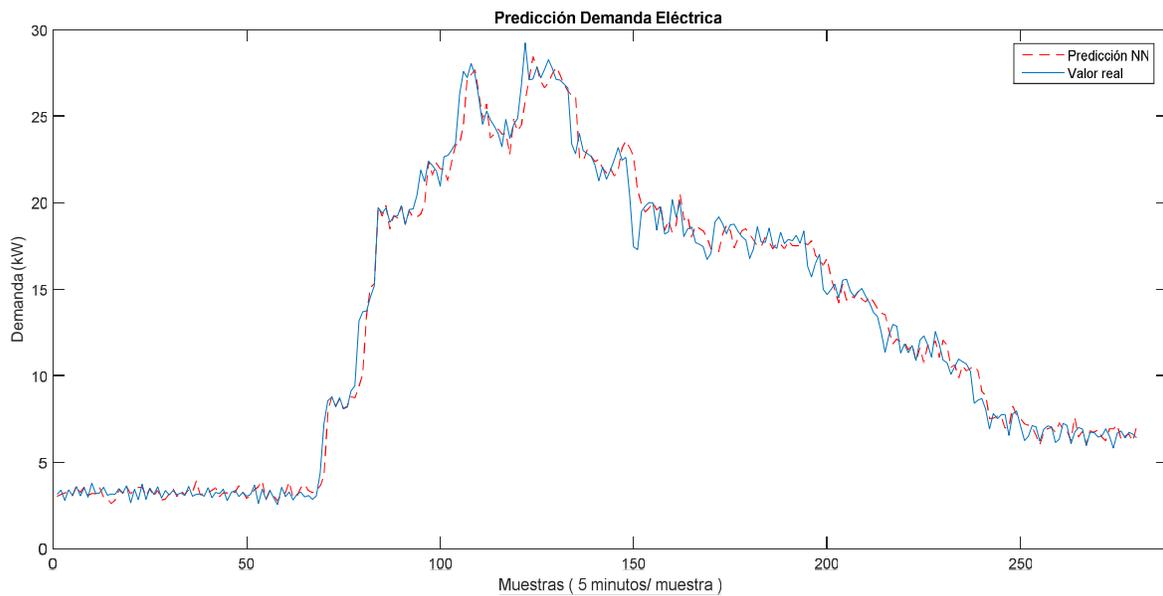


Figura 3.9.- Predicción de la demanda energética

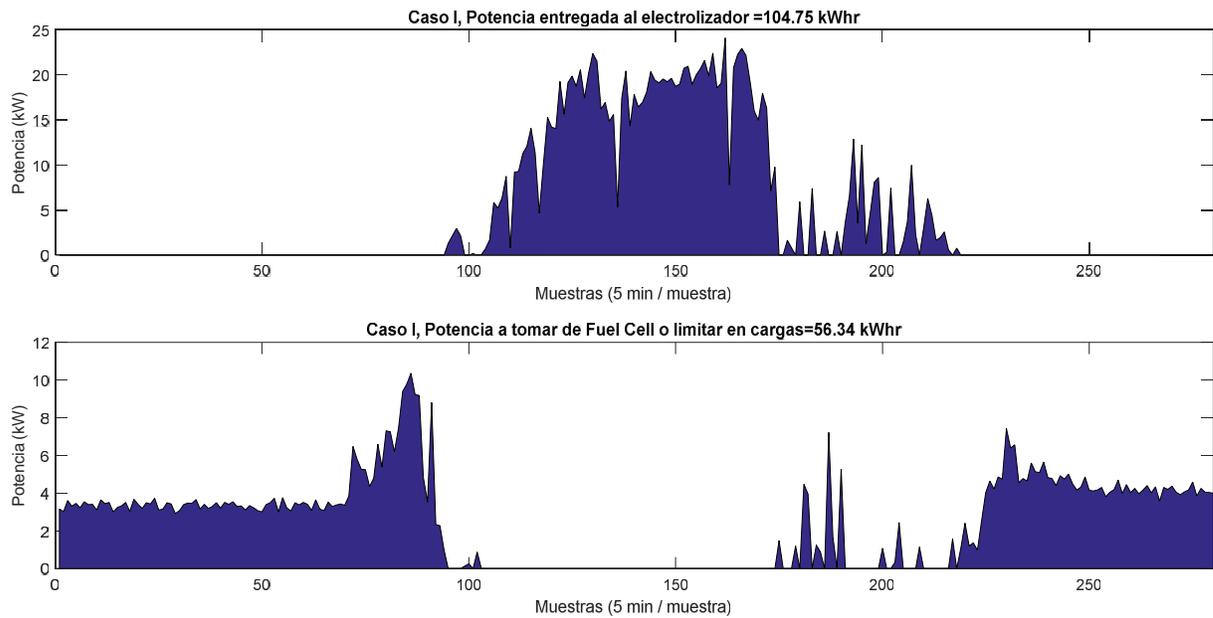


Figura 3.10.- Potencia entregada al electrolizador y potencia a demandar de la celda de combustible

De la figura 3.10 se puede apreciar que la generación del sistema fotovoltaico excede la demanda en un periodo de 6 horas aproximadamente, entregando energía al electrolizador de 104.75 kWh . Durante el resto del tiempo, la demanda excede a la generación en 56.34 kWh .

El excedente de energía es almacenado en forma de hidrógeno y será utilizada por la celda de combustible cuando la instalación fotovoltaica deje satisfacer la demanda. En la figura 3.11 se muestra la evolución en el tiempo de la eficiencia de Faraday del electrolizador y la producción de hidrógeno respectiva. A partir de este esquema, se requiere ahorrar limitando cargas, 24.9 kWh . Cuando el balance de energía en la predicción sea negativo, se pueden eliminar las cargas ordinarias (aire acondicionado, iluminación) para garantizar la autonomía energética.

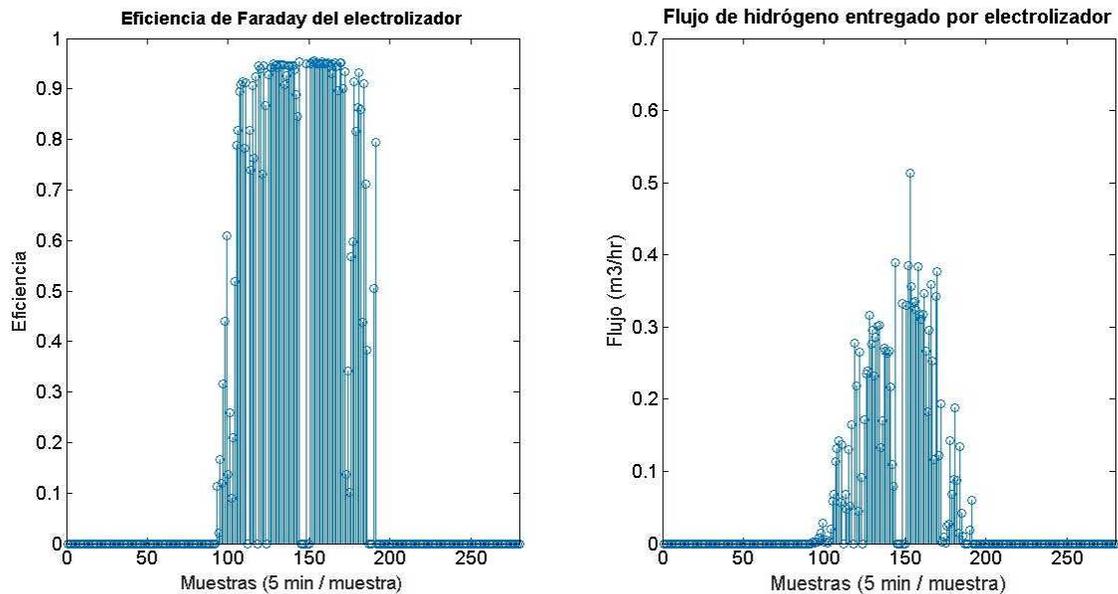


Figura 3.11.- Eficiencia de Faraday del electrolizador y flujo de Hidrógeno.

La microred eléctrica inteligente trabajará en un bus de DC y estará compuesta de las siguientes cargas principales:

- Sistema de generación fotovoltaica de 44 kW
- Electrolizador alcalino de 26 kW, 7 bar
- Celda de combustible de 7.5 kW a 24 VDC
- Carga eléctrica en bus de DC con potencia pico de 45 kW

Como condición de almacenamiento en el tanque de hidrógeno se especifica que al menos existan almacenados 0.1 kg de H₂.

3.3.-Operación del sistema de gestión de cargas energéticas.

En esta sección se procede a integrar la microred eléctrica con el sistema de gestión óptima energética por redes neuronales. El objetivo del sistema de gestión, basado en el algoritmo desarrollado por [40] y [7] es determinar las cantidades óptimas de flujo de energía para los sistemas solar fotovoltaico, electrolizador, celda de combustible buscando satisfacer la demanda compuesta por cargas críticas y cargas ordinarias. Se

propone un esquema que minimizar la descarga de cargas ordinarias y los costos de operación de las fuentes de energía de la microred.

El problema de gestión óptima es de programación lineal, y es resuelto utilizando el esquema de red neuronal dinámica descrita en el Capítulo 2 y desarrollada por [40], realizando los ajustes necesarios al problema de programación lineal original en el diseño propuesto por [7] donde se utiliza la red neuronal recurrente con restricciones flexibles en los costos energéticos y costos de operación de la microred. Este esquema puede extenderse al caso de costos dinámicos, donde el costo de la energía varía en función del tiempo, y también incluyendo diferentes fuentes de energía renovables y no renovables.

Se plantea el problema de optimización de la operación de la microred eléctrica como sigue:

$$\text{Minimizar} \quad C_O(t) = C_G P_G + C_P P_P + C_E P_E + C_F P_F + C_S P_S + C_S P_S$$

$$\text{Sujeto a} \quad P_P + P_F + P_S - P_S - P_E + P_G = L_C + L_O$$

donde

$C_O(t)$: Costo de operación total de la microred

C_G : Costo de operación al deshabilitar las cargas ordinarias

C_E : Costo de operación del electrolizador (\$/kW)

C_F : Costo de potencia entregada de la celda de combustible (\$/kW)

C_P : Costo de operación del sistema fotovoltaico (\$/kW)

C_S : Costo de potencia de carga de supercapacitor (\$/kW)

C_S : Costo de potencia entregada por el supercapacitor (\$/kW)

P_P : Potencia generada por el sistema fotovoltaico.

P_E : Potencia consumida por el electrolizador para almacenamiento de hidruros

P_F : Potencia generada por la celda de combustible

P_S : Potencia del supercapacitor en carga

P_S : Potencia del supercapacitor en descarga

L_C, L_o : Potencia consumida por cargas críticas y cargas ordinarias

P_G : Potencia a deshabilitar en cargas ordinarias

Para asegurar una operación estable de la microred se mantendrá el almacenamiento de hidruros por encima de un rango que asegure un respaldo energético en caso de desbalance en la ecuación de cargas. Por otra parte, debido a que la densidad de energía del banco de supercapacitores es relativamente baja comparada con el resto de las fuentes, en el problema de optimización se considerará como variable de gestión, pero su operación se verá reflejada de manera mínima en el flujo energético. Esto se debe a que la influencia del banco de capacitores es principalmente en la parte operativa para asegurar el arranque estable de los dispositivos de almacenamiento más que fungir como una fuente de energía para la microred.

La operación de la microred estará sujeta a las siguientes restricciones de carga

$$P_G(t) + P_P(t) + P_F(t) - L_C(t) - P_E(t) + P_{S_c}(t) - P_{S_o}(t) = 0$$

$$0 \leq P_G(t) \leq P_G$$

$$0 \leq P_P(t) \leq P_{P_l}$$

$$0 \leq P_F(t) \leq P_{F_l}$$

$$P_{E_l} \leq P_E(t) \leq P_{E_l}$$

$$P_{S_c}(t) = P_{S_c}(t) - P_{S_o}(t)$$

$$P_{S_c} \leq P_{S_c}(t) \leq P_{S_c}$$

$$P_{S_o} \leq P_{S_o}(t) \leq P_{S_o}$$

$$P_{S_o} \leq P_{S_o}(t) \leq P_{S_o}$$

$$P_{S_c} \leq P_{S_c}(t) \leq P_{S_c}$$

El problema de optimización será resuelto por una red dinámica recurrente de la forma

$$\dot{u} = -\alpha A^T A(t) + \alpha A^T b - \beta e^{-\delta} c$$

$$v_i(t) = \begin{cases} l_i & \text{si } u_i(t) < l_i \\ q_i & \text{si } u_i(t) > q_i \\ u_i(t) & \text{e } o \quad c_i \end{cases}$$

$$i = 1, 2, \dots, n; \quad u \in R^n, \quad \alpha, \beta, \delta \in R > 0$$

donde $v_i(t)$ son las variables de decisión que se encuentran acotadas por los vectores l y q .

Tabla 3.1.- Costos de operación de la microred.

Costos de operación	
C_G	0.98
C_{PV}	0.7
C_{EL}	0.77
C_{FC}	0.83
C_{SC}	0.07

Para resolver el problema de optimización por métodos de programación lineal planteamos las ecuaciones de restricción de la forma

$$P_G + s_1 = P_G$$

$$P_P + s_2 = P_P$$

$$P_F + s_3 = P_F$$

$$P_E + s_4 = P_E$$

$$P_S + s_5 = P_S$$

$$P_S + s_6 = P_S$$

Para la red neuronal dinámica, se seleccionan los siguientes parámetros de diseño en el modelo

$$\alpha = 2 \times 10^6$$

$$\beta = 1.5 \times 10^6$$

$$\delta = 0.5 \times 10^6$$

$$A = \begin{bmatrix} 1 & 1 & 1 & -1 & -1 & 1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & -1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & -1 & 1 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & -1 & 1 & 0 & 0 & 0 & 0 & 0 & -1 & 0 \end{bmatrix}$$

$$b = [L \quad P_G \quad P_{PI} \quad P_{FC} \quad P_{El} \quad P_S \quad P_S \quad P_S \quad P_S \quad n]$$

El algoritmo de gestión de la microrred eléctrica inteligente se validará considerando un día típico donde la demanda neta del día es de aproximadamente 300 kWh. El objetivo del sistema de gestión es garantizar la autonomía energética, utilizando la predicción de series de tiempo de la demanda energética y la generación fotovoltaica. A partir de las predicciones y el esquema tarifario que se tenga, el algoritmo determinará si es necesario realizar almacenamiento de energía en forma de hidrógeno y cuando esta debe ser utilizada, tomando como restricciones los requerimientos de estado de carga máximo y mínimos del tanque de almacenamiento. Por otra parte, en el caso en que la potencia actual entregada por el sistema fotovoltaico y la celda de combustible no sea suficiente para satisfacer la demanda, el sistema de gestión determinará la cantidad potencia que deberá eliminarse en las cargas ordinarias. La selección de cargas ordinarias se establece previamente de acuerdo a las políticas de gestión energética del proceso.

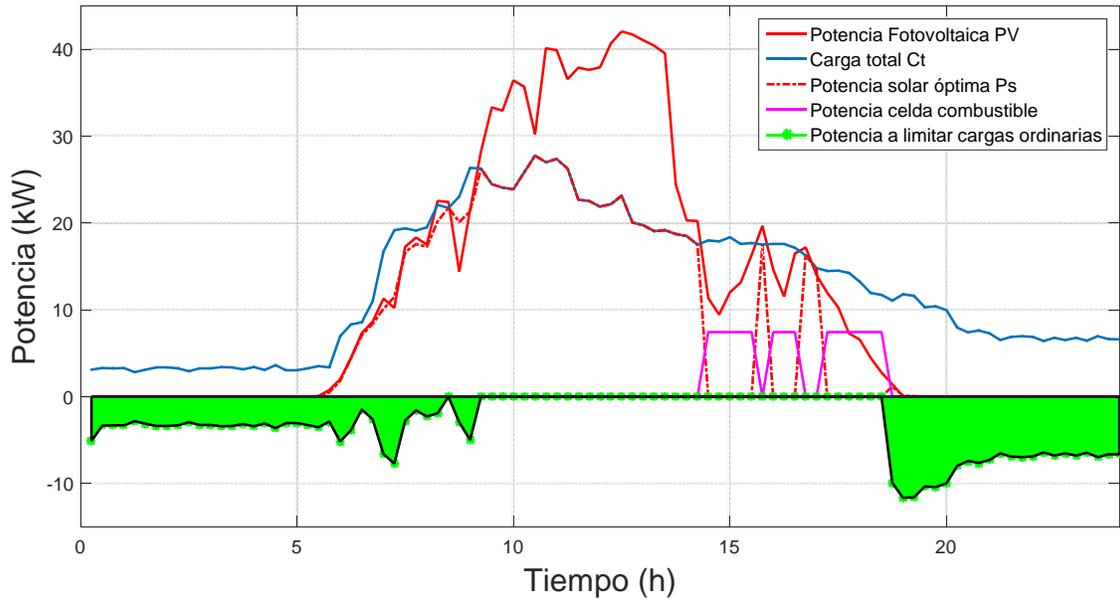


Figura 3.12. Flujo de potencia en la microred con sistema de gestión

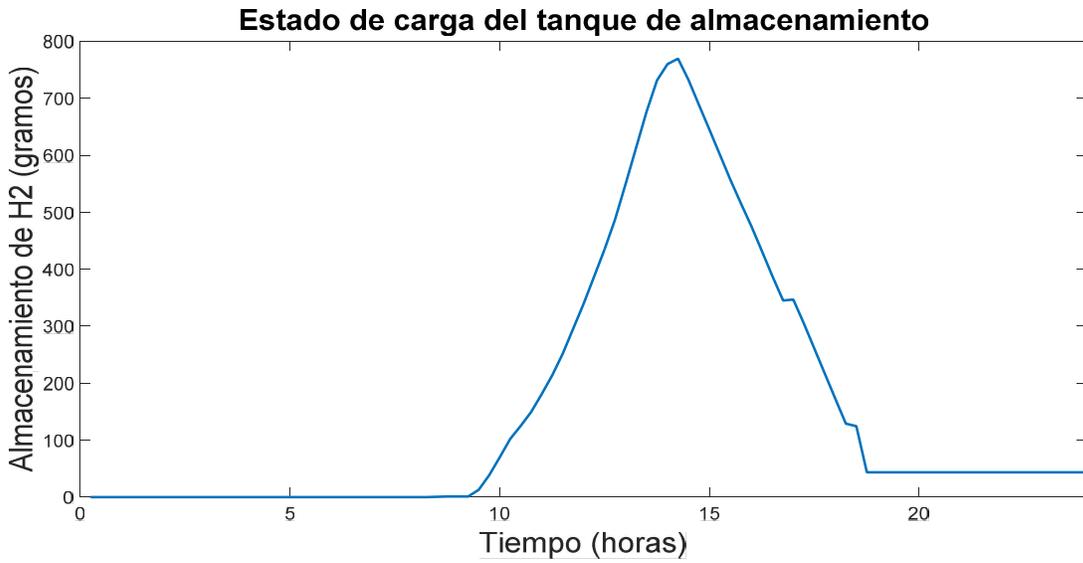


Figura 3.13. Masa de hidrógeno en el tanque de almacenamiento

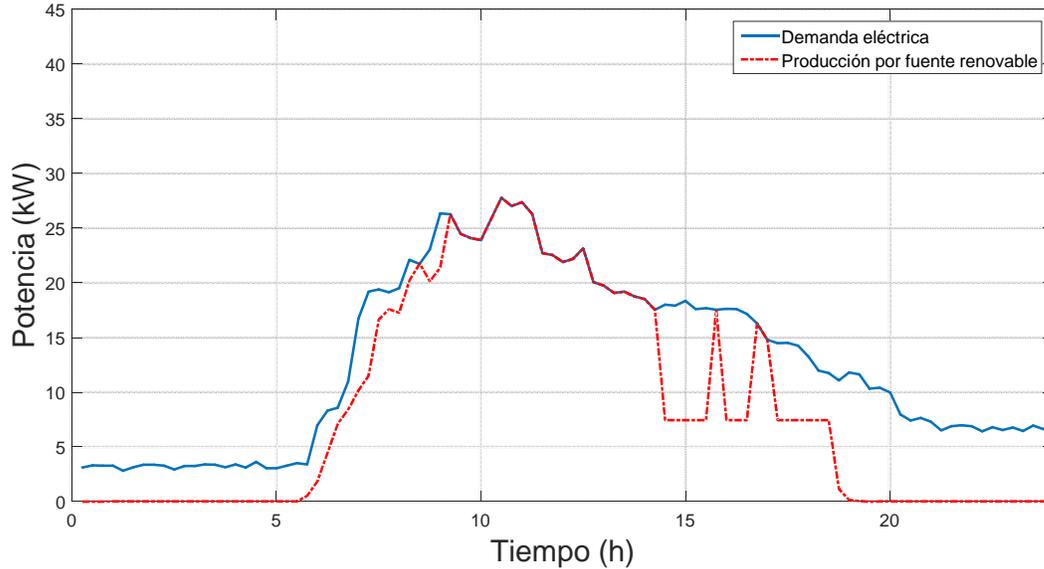


Figura 3.14. Demanda eléctrica contra producción por energía renovable

La figura 3.12 muestra la evolución en el tiempo de las fuentes de energía de la microred y la figura 3.13 el estado de carga para el tanque de almacenamiento de hidrógeno. Se puede observar que durante el día la generación fotovoltaica excede la demanda, y es a energía sobrante es almacenada en forma de hidrógeno. Aproximadamente las 14hrs la demanda excede a la producción y en ese momento se obtiene esa energía a partir de la celda de combustible. En el momento en el cual la energía proporcionada por el sistema fotovoltaico y/o la celda de combustible es insuficiente para satisfacer la demanda se debe limitar las cargas ordinarias. La figura 3.14 muestra la aportación por fuentes de energía alternativa a la microred donde el algoritmo de gestión establece la cantidad de potencia que debe ser descargada de la red con el objeto de garantizar la autonomía energética.

El sistema de gestión determina los flujos óptimos de energía en función de los costos instantáneos y asigna variables de decisión para determinar si es conveniente almacenar energía o eliminar cargas ordinarias de la red cuando la demanda sea mayor a la generación y la energía almacenada.

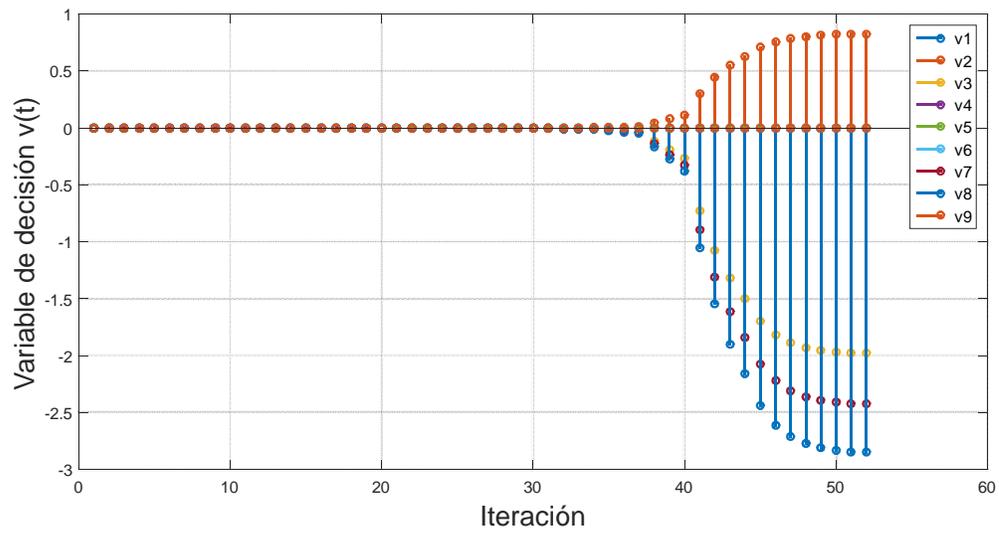


Figura 3.15. Evolución de las variables de decisión

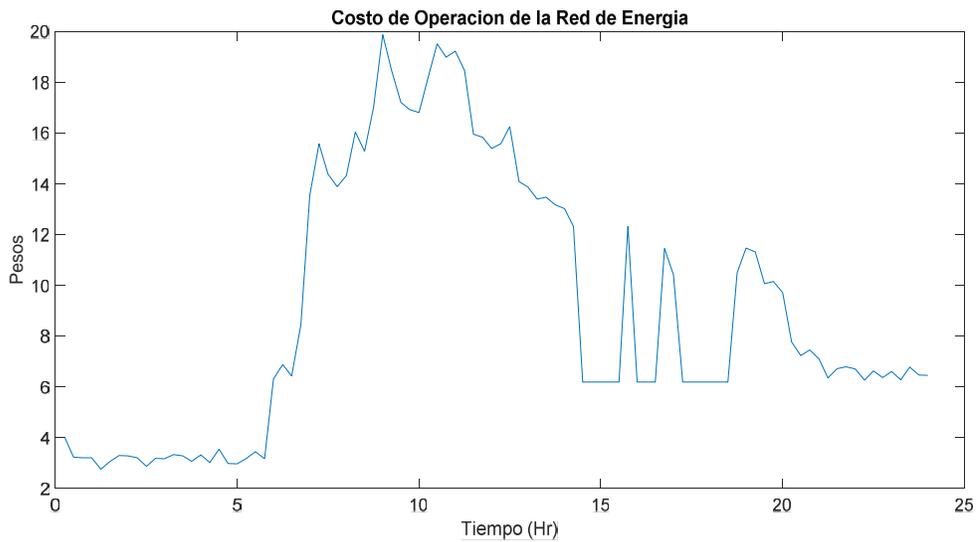


Figura 3.16. Costo de operación de la microred

La Figura 3.15 muestra la evolución de las variables de decisión, que muestra la velocidad de convergencia de la red neuronal. Esta es una de las principales ventajas de la red, ya que la operación de una microred requiere una actualización de las variables de decisión

con mayor rapidez que la frecuencia de muestreo de los dispositivos de medición, que por lo general es de 10 min. La red neuronal determina la solución óptima del problema de programación lineal en 57 iteraciones en promedio, lo cual resulta en un tiempo de cómputo de alrededor de 5 segundos. La Fig. 3.16 muestra la evolución en el tiempo de los costos energéticos de la microred incluyendo el costo de la potencia que requiere ser descargada en cargas ordinarias, que en este caso fue de 71 kWh en total. A partir de estos datos el costo diario de operación de la microred utilizando fuentes alternativas es de 869 pesos diarios, este costo puede ser reducido al eliminar las cargas ordinarias del sistema, cuando esto sea requerido.

CONCLUSIONES

Descripción de los resultados de la tesis

En este trabajo de tesis se utilizan herramientas de inteligencia computacional para mejorar la operación de una red eléctrica inteligente. En particular se aplican redes neuronales artificiales para

- Estimación de las curvas Voltaje-Corriente y Voltaje-Potencia para módulos fotovoltaicos a partir de las condiciones de irradiación, mediante redes neuronales estáticas multicapa.
- Predicción de la generación de potencia de instalaciones fotovoltaicas, demanda de edificios, utilizando redes neuronales recurrentes de alto orden.
- Gestión de cargas y generación en una microred utilizando redes neuronales dinámicas para solución de problemas de programación lineal.

Se obtuvieron los modelos matemáticos de cada fuente de energía que participa en la microred compuesto de un arreglo de paneles fotovoltaicos, un electrolizador, una celda de combustible y un banco de capacitores. Los resultados se han validado utilizando mediciones reales y simulaciones de modelos comerciales ya reportados en la literatura.

Se obtuvieron los modelos matemáticos de cada fuente de energía que participa en la microred compuesto de un arreglo de paneles fotovoltaicos, un electrolizador, una celda de combustible y un banco de capacitores. Los resultados se han validado utilizando mediciones reales y simulaciones de modelos comerciales ya reportados en la literatura.

Utilizando la predicción de la serie de tiempo de la generación de potencia del sistema fotovoltaico y la predicción de la demanda energética, se estimó la generación de hidrógeno mediante un electrolizador alcalino utilizando un modelo en simulación a partir del modelo matemático desarrollado en esta tesis. El modelo en simulación del sistema fotovoltaico-electrolizador mostró resultados similares a los reportados en la literatura.

Conclusiones

En este trabajo se presentó una metodología para el diseño de una microred eléctrica mediante técnicas de modelado matemático y aproximación por redes neuronales para las características de generación de potencia de un arreglo de módulos fotovoltaicos y una celda de combustible conectados a una conexión de corriente directa y un sistema de almacenamiento de hidrógeno.

Las técnicas de aproximación de curvas características módulos fotovoltaicos y electrolizador utilizando redes neurales recurrentes entrenadas con el filtro de Kalman, tuvieron un excelente desempeño en comparación con aplicaciones similares reportadas en la literatura. La principal ventaja de estos esquemas es su rapidez de convergencia y un excelente desempeño ante curvas de alta variabilidad.

Finalmente, el modelo en simulación de la microred se integró con el sistema de gestión energética, estableciendo un problema de programación lineal donde una red neuronal dinámica determina la solución para variables de decisión del flujo energético. El desempeño del algoritmo de red dinámica es muy bueno, dando una respuesta rápida dentro de los parámetros necesarios para el correcto funcionamiento de la microred. Se presentó un ejemplo de gestión energética para un día típico en el cual el excedente de la generación fotovoltaica fue almacenado y reutilizado a partir de una celda de combustible con una eficiencia cercana a 30%. El algoritmo de gestión de cargas tiene una rápida convergencia de alrededor de 5 segundos lo cual lo hace muy viable para aplicaciones en tiempo real, ya que en general en aplicaciones en campo las mediciones y tomas de decisiones se realizan en periodos de 10 a 15 minutos.

La principal ventaja de las técnicas de inteligencia computacional presentadas en esta tesis es el disponer de una herramienta confiable para el pronóstico de la producción energética y la correspondiente producción de hidrógeno utilizando las redes neuronales artificiales.

Los resultados de este trabajo podrán extenderse para incluir diferentes tipos de fuentes de energía ya sean renovables o convencionales, además de poder considerar costos dinámicos.

Un esquema de gestión de microred puede ser implementado en un futuro en situaciones de mercado energético para poder tomar decisiones de cuando adquirir energía de un cierto tipo y cuando poder venderla basándose en predicciones.

Referencias

- [1] Torres F, Energías Renovables para el Desarrollo Sustentable en México, Secretaría de Energía (SENER), 2006.
- [2] NREL, Distributed Generation Renewable Energy Estimate of Costs, Fecha de acceso 5 de enero de 2015 del sitio web del National Renewable Energy Laboratory, http://www.nrel.gov/analysis/tech_lcoe_re_cost_est.html#biblio.
- [3] Hidaka Y, Modeling of a hybrid system of photovoltaic and fuel cell for operational strategy in residential use, en 47th International Universities Power Engineering Conference (UPEC), London, 2012.
- [4] Osswald M, Experience with zero emission hybrid systems solar, wind, batteries and fuel cells for off-grid base stations, en Telecommunications Energy Conference Smart Power and Efficiency (INTELEC), Hamburg, 2013, 1-5.
- [5] Nayar C, Novel wind/diesel/battery hybrid energy system, *Solar Energy* 51, 65-78, 1993.
- [6] Ricalde L, Time Series Forecasting via a Higher Order Neural Network trained with the Extended Kalman Filter for Smart Grid Applications, en *Artificial Higher Order Neural Networks for Modeling and Simulation*, Zhang M, Ed.; IGI Global, USA, 2013, 254-274.
- [7] Gamez M, Optimal Operation via a Recurrent Neural Network of a Wind- Solar Energy System, en International Joint Conference on Neural Networks, San José California, 2011, 2222-2228.
- [8] Tischer H; Verbic G, Towards a smart home energy management system - A dynamic programming approach, en Innovative Smart Grid Technologies Asia (ISGT), Anaheim, 2011, 1-7.
- [9] Ishida T, Self-organization model for the energy cluster formation with distributed energy network, en IEEE Computational Intelligence Applications in Smart Grid (CIASG), Singapore, 2013, 161-166.

- [10] Marion B, PVWATTS - An Online Performance Calculator for Grid-Connected PV Systems, en Proceedings SES Solar Conference, Madison, WI, 2000, 1-6.
- [11] King D, Performance Model for Grid-Connected Photovoltaic Inverters, SAND2007-5036, Sandia National Laboratories, 2007.
- [12] Sandrolini L, Numerical method for the extraction of photovoltaic module double-diode model parameters through cluster analysis, *Applied Energy* 87, 442-451, 2010.
- [13] De Soto W, Improvement and validation of a model for photovoltaic array performance, *Solar Energy* 80, 78-88. 2006.
- [14] Alanís A, High Order Neural Networks for Wind Speed Time Series Prediction, en Proceedings of the IEEE International Joint Conference on Neural Networks, Atlanta , 2009, 76-80.
- [15] Haykin S, *Neural Networks*, Prentice Hall, USA, 1999.
- [16] Holtschneider T, Optimization of Electricity Pricing Considering Neural Network based Model of Consumers Demand Response, en IEEE Computational Intelligence Applications in Smart Grid (CIASG), Singapore, 2013, 154-160.
- [17] Shin-Yeu L, Distributed optimal power flow for smart grid transmission system with renewable energy sources, *Energy* 56, 184-192, 2013.
- [18] Battistelli C, Optimal management of the automatic generation control service in smart user grids including electric vehicles and distributed resources, *Electric Power System Research* 111, 22-31, 2014.
- [19] Yan Y, A Survey on Smart Grid Communication Infrastructures: Motivations, Requirements and Challenges, *IEEE Communications Surveys & Tutorials* 15, 5-20, 2013.
- [20] Corona V, Control de voltaje mediante inversores fotovoltaicos en redes eléctricas inteligentes, Tesis de Maestría, Universidad Autónoma de Yucatán, México 2014.

- [21] Goetzberger A, *Photovoltaic Solar Energy Generation*, Springer-Verlag, Germany, 2014.
- [22] Secretaría de Energía, *Prospectiva del sector eléctrico 2015-2029*, México, 2015.
- [23] Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas (CIEMAT), *Informe de vigilancia tecnológica, tendencias tecnológicas mundiales en el desarrollo y aplicación de paneles solares fotovoltaicos*, España, 2009.
- [24] National Renewable Energy Laboratory, Best Cell Efficiencies, fecha de acceso 30 de mayo de 2015, del sitio web del NREL, http://www.nrel.gov/pv/assets/images/efficiency_chart.jpg, 2013.
- [25] Sánchez E, *Redes Neuronales*, Pearson, España, 2006.
- [26] Ashari M; Nayar C, An Optimum Dispatch Strategy using set points for a Photovoltaic (PV)–Diesel-Battery Hybrid Power System, *Solar Energy* 66, 1-9, 1999.
- [27] Newnham R; Baldsing W, Benefits of partial-state-of-charge operation in remote-area power-supply systems, *Journal of Power Systems* 107, 273-279, 2002.
- [28] Dehbonei H; Nayar C, A New Modular Hybrid Power System, en IEEE International Symposium on Industrial Electronics , Rio de Janeiro, 2003, 985 – 990.
- [29] German Energy Society, *Planning and Installing Photovoltaic Systems: A Guide for installers, architects and engineers*, Earthscan Publications, Germany, 2008.
- [30] Rahman S, A feasibility study of photovoltaic-fuel cell hybrid energy system, *IEEE Transactions on Energy Conversion* 3, 50-55, 1988.
- [31] Haddad A; Mannah M; Bazzi H, Nonlinear time-variant model of the PEM type fuel cell for automotive applications, *Simulation Modelling Practice and Theory* 51, 31–44, 2015.
- [32] Moreira M; da Silva G, A practical model for evaluating the performance of proton exchange membrane fuel cells, *Renewable Energy* 34, 1734–1741, 2009.

- [33] Saisset R, Contribution à l'étude systémique de dispositifs énergétiques à composants électrochimiques, Ph.D. Thesis, Laboratoire d'Electrotechnique et d'Electronique Industrielle de l'ENSEEIH, France, 2004.
- [34] Nehrir M, *Modeling and Control of Fuel Cells Distributed Generation Applications*, Wiley, New York, 2009.
- [35] Sedlakova V; Sikula J; Majzner J; Sedlak P; Kubarowicz T; Buegler B; Vasina P, Supercapacitor equivalent electrical circuit model based on charges redistribution by diffusion, *Journal of Power Sources* 286, 58-65, 2015.
- [36] Ulleberg Ø, Modeling of advanced alkaline electrolyzers: a system simulation approach, *International Journal of Hydrogen Energy* 28, 21–33, 2003.
- [37] Cao L, Practical method for determining the minimum embedding dimension of a scalar time series, *Physica D: Nonlinear Phenomena* 110, 43-50, 1997.
- [38] Kennel M; Brown R; Abarbanel H, Determining the embedding dimension for phase-space reconstruction using a geometrical construction, *Physical Review A* 45, 3403-3411, 1992.
- [39] Wang J, Analysis and design of a recurrent neural network for linear programming, *IEEE Trans Circuits Syst*, 40, 613-618, 1993.
- [40] Bonanno F; Capizzi G; Graditi G; Napoli C; Tina G, A radial basis function neural network based approach for the electrical characteristics estimation of a photovoltaic module, *Applied Energy* 97, 956–961, 2012.

Anexos:

Anexo 1. Hoja de datos del panel fotovoltaico S60MC.



Solartec
Energía Renovable

MONOCRYSTALLINE

245 – 265 W SOLAR PANEL
EXCEPTIONAL EFFICIENCY AND PERFORMANCE /
EFICIENCIA Y DESEMPEÑO EXCEPCIONAL

BENEFITS / BENEFICIOS

High Efficiency / Alta Eficiencia

High cell efficiency of up to 15%.
Líder en la industria con una eficiencia de las celdas superior.

More Power / Mayor Potencia

Delivers up to 50% more power per unit area than conventional solar panels and 100% more than thin film solar panels.
Ofrece hasta un 50% más de potencia por unidad de Área a comparación de los paneles solares convencionales y un 100% más que los paneles solares de película delgada.

Reduces Installation Cost / Reducción en Costos de Instalación

More power per unit means fewer modules per installation. This saves both time and money.
Más potencia por paneles representa menos módulos por instalación. Esto ahorra tanto tiempo como dinero.

Reliable and Robust Design / Diseño Robusto y Confiable

Certified materials, tempered front glass, and a sturdy anodized frame allows the module to operate reliably in multiple mounting configurations.
Materiales certificados, cristal templado y un robusto marco anodizado el cual permite al módulo operar sin problemas seguros y en múltiples configuraciones de montaje.



S60MC

60 Cell Modules
S60MC-245, S60MC-250, S60MC-250,
S60MC-255, S60MC-260, S60MC-265



Solartec 245 – 265W solar modules provide industry leading efficiency and performance.
Utilizing 60 next generation solar cells and an optimized module design, Solartec S60MC solar modules deliver and unprecedented conversion efficiency. Solartec 245 – 265W modules reduced voltage – temperature coefficient, and exceptional low – light performance attributes, provide far higher energy delivery at peak power than conventional modules.

Los módulos solares Solartec de 245 – 265 W proveen un liderazgo incomparable en la industria gracias a su eficiencia y desempeño.

El módulo solar S60MC utiliza 60 celdas solares de última generación, aunado al óptimo diseño del módulo, permitiéndole ofrecer una eficiencia superior. El reducido valor del coeficiente de voltaje-temperatura, y su desempeño excepcional en condiciones de baja iluminación permiten a los módulos de 245 – 265W entregar mucha mayor energía en condiciones de potencia máxima, en comparación con los módulos convencionales.

Tested Operating Conditions / Condiciones de Operación	
Temperature / Temperatura	-40° C to +90°C (-40°F to +194°F)
Max load / Carga Máxima	50 psf (2400 pasels) front and back
Impact Resistance / Resistencia al Impacto	Hail @ 25mm (1 in.) at 23 m/s (52mph)
Complies with / Normado con	IEC 61215 / IEC 61730 / NMX-J 618

S60MC

www.solartec.mx



245 – 265 W SOLAR PANEL

EXCEPTIONAL EFFICIENCY AND PERFORMANCE / EFICIENCIA Y DESEMPEÑO EXCEPCIONAL

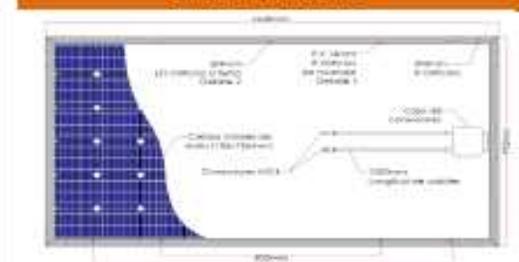
Especificaciones / Especificaciones		IV Curve			
Number of cells / Número de células	60 (6 x 10)				
Module dimensions / Dimensiones del módulo	1640mm x 992mm				
Weight / Peso	18.5 kg				
Cable / cable	1000mm long double XLPE layer, TÜV Certified, 4.00mm ²				
Connection / Conexión	IP65 Type IV Junction box with 6 bypass diodes, MC4 type Plug, TÜV Certified				
Back Sheet / Hoja Trasera	White/Black/Blue TFT or Glass	Maximum system voltage / Voltaje máximo del sistema	600 V	Maximum series fuse / Valor máximo del fusible en serie	15 A
Frame / Marco	Aluminium (40 mm) or Without frame				
Fire Rating / Clasificación de Fama	Class C				

156mm Monocrystalline Silicon Cells Solar Module / Panel Solar con Células de 156mm de Silicio Monocristalino

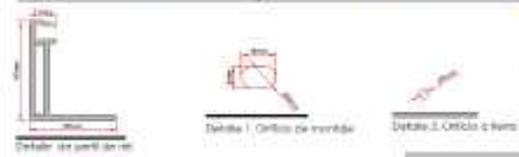
Model / Modelo	S60MC-245		S60MC-250		S60MC-255		S60MC-260		S60MC-265	
Test Conditions / Condiciones de Medición	STC	NOCT								
Open circuit voltage (Voc) / Voltaje de circuito abierto	36.80 V	35.44 V	37.30 V	35.84 V	37.40 V	35.92 V	38.00 V	36.40 V	38.30 V	36.64 V
Optimum operating voltage (Vmp) / Voltaje en el punto de máxima potencia	30.10 V	28.08 V	30.50 V	28.40 V	30.60 V	28.48 V	31.10 V	28.88 V	31.30 V	29.04 V
Short circuit current (Isc) / Corriente de cortocircuito	8.65 A	8.82 A	8.74 A	8.99 A	8.85 A	7.08 A	8.89 A	7.11 A	8.02 A	7.21 A
Optimum operating current (Imp) / Corriente en el punto de máxima potencia	8.13 A	6.50 A	8.21 A	6.56 A	8.32 A	6.65 A	8.35 A	6.68 A	6.48 A	6.78 A
Maximum power (Pmax) / Potencia máxima	245 W	196 W	250 W	200 W	255 W	204 W	260 W	208 W	265 W	212 W
Module efficiency / Eficiencia del módulo	15.05%		15.38%		15.67%		15.98%		16.28%	

Temperature Coefficients / Coeficientes de Temperatura					
Of Isc / de Isc (α)	+0.036% / °C	Of Voc / de Voc (β)	-0.346% / °C	Of Pmax / de Pmax (γ)	-0.47% / °C

Dimensions / Dimensiones



Aluminium Frame / Marco de Aluminio



Warranty / Garantía

Materials comprising photovoltaic modules and any possible defects due to the manufacturing process for 10 years.
 Los materiales que componen los paneles fotovoltaicos y los posibles defectos que se originan al momento de la fabricación por un periodo de 10 años.
 At least 80% output power provided by the photovoltaic module over 10 years.
 Generación mínima del 80% de la potencia de salida nominal del módulo a los 10 años.
 At least 80% output power provided by the photovoltaic module over 25 years.
 Generación mínima del 80% de la potencia de salida nominal del módulo a los 25 años.
 Measured under standard test conditions and normal operating cell temperature (STC: 1000W/m², 25°C, AM 1.5; NOCT: 800W/m², 45°C, AM 1.5.)
 Medido bajo condiciones de prueba estándar y bajo condiciones de temperatura de operación nominal de la célula (STC: 1000W/m², 25°C, AM 1.5; NOCT: 800W/m², 45°C, AM 1.5.)
 The electric characteristics of each photovoltaic module are individually monitored leaving the results available to the customer. Warranted Tolerance ±1%
 Las características eléctricas de cada módulo fotovoltaico son monitoreadas individualmente dejando los resultados a disposición del cliente. Tolerancia garantizada ±1%.

Applications / Aplicaciones

- Building Integration / Integración estructural
- Solar Power kits and Plants / Plantas de energía solar
- Solar Pumping Systems / Sistemas de bombeo solar
- Energy Bill Savings / Reducción de costos en energía

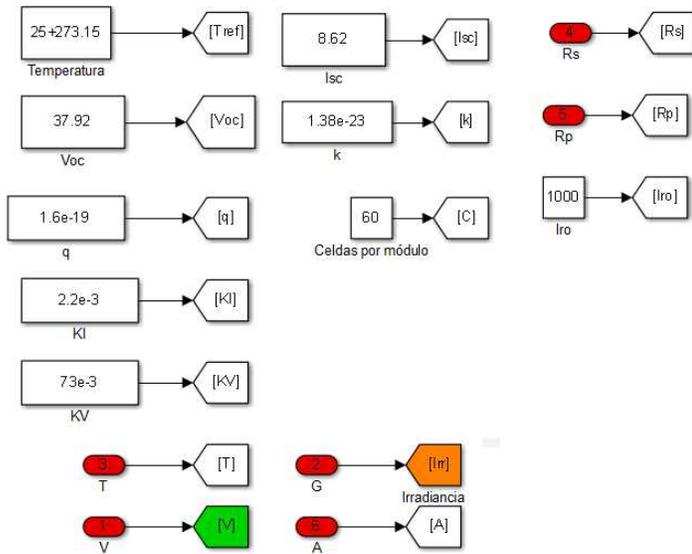
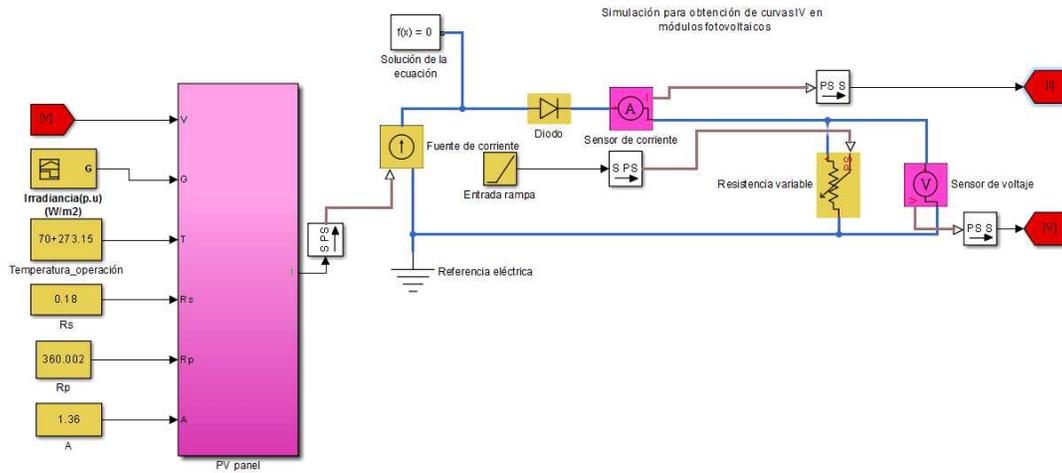
Distributed by / Distribuido por

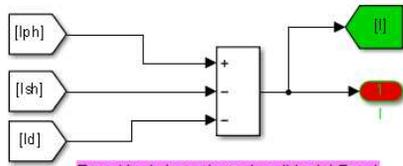


Contact / Contacto: Carretera Libramiento Norte Km 4.6
 Lote No. 9, Parque Industrial Apolo
 Insueta, Cto. México CP 36036
 Phone Number +52 (662) 635 9638
 Email: info@solartec.mx



Anexo 2.



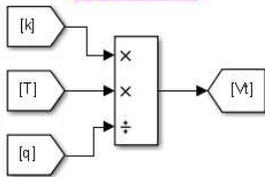


Ecuación de la corriente de salida del Panel

$$I = I_{ph} - I_d - I_{sh}$$

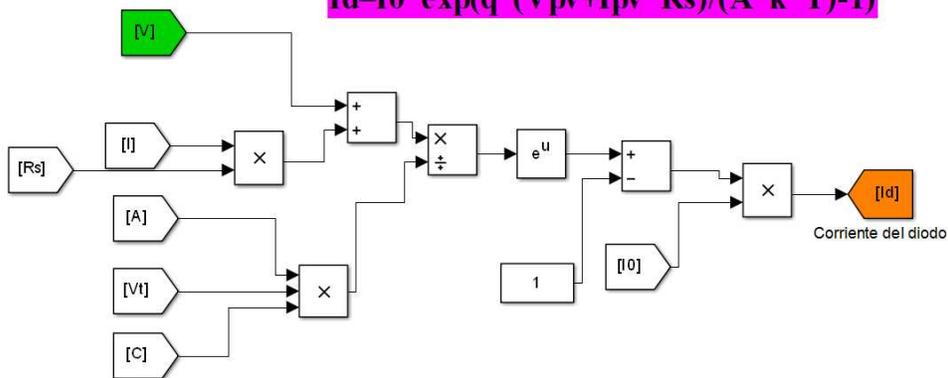
Ecuación de caída de voltaje por temperatura

$$V_t = k \cdot T / q$$



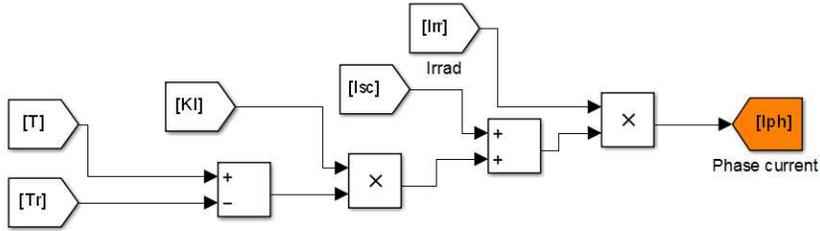
Ecuación de la corriente del diodo

$$I_d = I_0 \cdot \exp\left(\frac{q \cdot (V_{pv} + I_{pv} \cdot R_s)}{A \cdot k \cdot T} - 1\right)$$



Corriente por efecto fotoeléctrico

$$I_{ph} = I_{sc} + k_i(T - T_r) * G$$



Ecuación de corriente de saturación

$$I_0 = I_{or} * ((T/T_r)^3) * \exp((q * E_g) / (K * A)) * (1/T - 1/T_r)$$

