

DISEÑO DE UNA MICRO RED ELÉCTRICA INTELIGENTE CON SISTEMA FOTOVOLTAICO Y CELDA DE COMBUSTIBLE

Erika H. Rubio Cámara

Centro de Investigación Científica de Yucatán
eri.hy.erc@hotmail.com

Luis C. Ordoñez López

Centro de Investigación Científica de Yucatán

Luis J. Ricalde Castellanos

Universidad Autónoma de Yucatán, Facultad de Ingeniería
lricalde@correo.uady.mx

Emmanuel de la Cruz May

Universidad Autónoma de Yucatán, Facultad de Ingeniería
eri.hy.erc@hotmail.com

Ricardo J. Peón Escalante

Universidad Autónoma de Yucatán, Facultad de Ingeniería
eri.hy.erc@hotmail.com

Resumen

En este trabajo, se propone diseñar una microred eléctrica compuesta por sistemas de generación fotovoltaico, celda de combustible y una fuente de respaldo por supercapacitor integrados en un bus de DC (corriente directa). Las variables de radiación solar se caracterizarán con los datos experimentales de una estación meteorológica y la generación fotovoltaica y por 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). La base de conocimientos para predicción de la microred utiliza los

modelos matemáticos de los elementos de generación; las predicciones de generación de energía y demanda de carga se obtienen mediante redes neuronales que serán entrenadas con un algoritmo basado en el filtro de Kalman.

Palabra(s) Clave(s): gestión energética, red eléctrica inteligente, redes neuronales, sistema fotovoltaico, tecnología de hidrógeno.

1. Introducción

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

Recientemente, 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 en mediana escala se ha reducido hasta un rango de 2000 a 4000 USD; siendo los más bajos, seguido de la energía eólica con un costo 3000 a 8000 USD por kW instalado [1]. Actualmente hay muchos trabajos para la integración de las energías renovables a redes eléctricas públicas como consecuencias de esta reducción de los costos [2], [3], [4]. 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 [5]. 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.

La demanda de la red eléctrica inteligente en general no coincide en el tiempo con la generación de fuentes renovables, la red 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. El uso de estas tecnologías se ha incrementado a pesar que los costos actuales de los componentes (electrolizador, tanque de hidrógeno y celdas de combustible) son altos. Un esquema de almacenamiento por hidrógeno puede implementarse en el diseño de microredes para garantizar la sustentabilidad energética de un edificio.

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 hidruros metálicos y emplear posteriormente una celda de combustible cuando la generación disminuya por debajo de la demanda. Tischer and Verbic [6] 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. Ishida, [7], 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. Con el fin de predecir la generación de energía a partir de una serie de módulos fotovoltaicos, en [8] y [9], propusieron el uso de modelos matemáticos para caracterizar sistemas de generación que constan de módulos fotovoltaicos y circuitos eléctricos con diferentes topologías. En [10] se 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.

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 [11]. Las redes recurrentes están basadas en el modelo de Hopfield y son consideradas como buenas candidatas para aplicaciones de sistemas no lineales que tratan con incertidumbres y son atractivas debido a su fácil implementación, estructura relativamente simple, robustez y la capacidad de ajustar sus parámetros en línea [12]. 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 [13] 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 pueden 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.

En este trabajo, se modela matemáticamente las características de generación de potencia de una microred eléctrica compuesta de un arreglo de módulos fotovoltaicos y una celda de combustible conectados a un bus de corriente directa y un sistema de almacenamiento de hidrógeno. Además, se diseña un algoritmo basado en redes neuronales artificiales para aproximar a los valores reales la generación de potencia, y las curvas corriente-voltaje de los sistemas fotovoltaicos y producción de hidrógeno.

2. Desarrollo

Sistemas Fotovoltaicos

Los elementos que constituyen un sistema fotovoltaico son: módulo fotovoltaico, baterías, elementos de acondicionamiento de potencia, estructuras y accesorios. Un módulo fotovoltaico es un dispositivo diseñado para captar parte

de la radiación emitida por el sol y convertirla en energía eléctrica electricidad mediante el efecto fotovoltaico. Las celdas fotovoltaicas se pueden utilizar en conexión con la red eléctrica, o bien en sitios aislados, por medio de sistemas de almacenamiento.

Las características corriente-voltaje de una celda fotovoltaica se caracterizan por el modelo de diodo propuesto por ecuación 1, [14].

$$\begin{aligned}
 I_{PV} &= I_{ph} - I_0 \left(\exp \left(\frac{q(V_{PV} + I_{PV}R_s)}{AKT} \right) - 1 \right) - \frac{V_{PV} + I_{PV}R_s}{R_{sh}} \\
 I_0 &= I_{or} \left(\frac{T}{T_r} \right)^3 \exp \left(\frac{qE_G}{KA} \left(\frac{1}{T_r} - \frac{1}{T} \right) \right) \\
 I_{ph} &= (I_{scr} + k_i(T - T_r)) \frac{\lambda}{100}
 \end{aligned}
 \tag{1}$$

Donde I_{PV} es la corriente de salida de la celda, I_{ph} es la corriente de luz, I_0 es la corriente de saturación del diodo, I_{scr} es la corriente de corto circuito, A es el factor de idealización, E_G es el ancho de banda para el silicio, K es la constante de Boltzmann, k_i el coeficiente de temperatura de corto circuito a I_{scr} , q es la carga del electrón, R_s, R_{sh} son las resistencias en serie y shunt respectivamente. T es la temperatura de la celda fotovoltaica, T_r la temperatura de referencia, V_{PV} el voltaje de salida de la celda y λ la radiación. Se puede ver que la temperatura tiene un efecto negativo sobre el rendimiento del panel.

En este proyecto se trabajará con un arreglo fotovoltaico compuesto de módulos solar S60MC el cual utiliza 60 celdas solares monocristalinas con una potencia total de 250 W.

Para crear un modelo en simulación de una celda fotovoltaica se utilizan los datos ambientales radiación solar (W/m^2) y temperatura ambiente ($^{\circ}C$). La figura 1 muestra las curvas típicas de irradiación para la ciudad de Mérida, de la estación meteorológica de la Facultad de Ingeniería de la UADY para el año 2013; la tabla 1 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 se enumeran los parámetros necesarios para implementar un modelo en simulación de un módulo fotovoltaico S60MC.

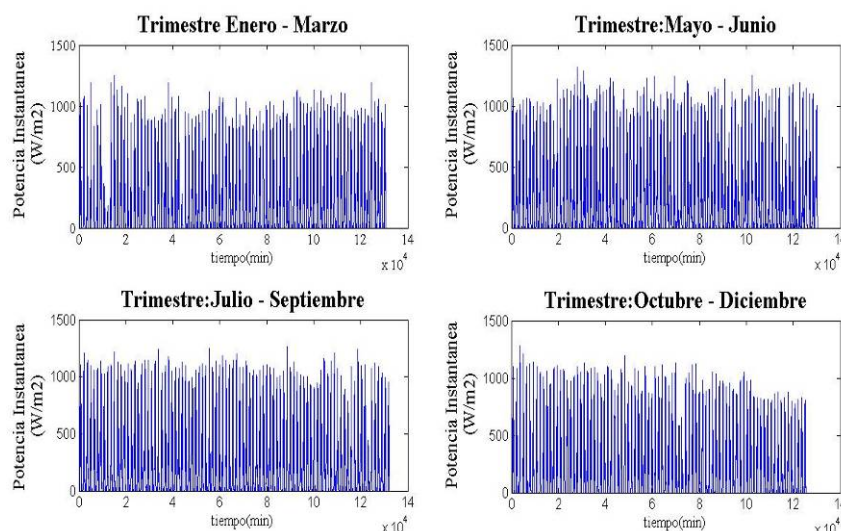


Figura 1 Curvas de irradiación diaria para la ciudad de Mérida (año 2013).

Tabla 1 Irradiación promedio diaria para la ciudad de Mérida (año 2013).

Mes	Irradiación promedio diario (kW*h/m²)
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

Tabla 2 Parámetros de simulación para el módulo S60MC.

Parámetro	Valor para modelo S60MC
ISC	8.62 A
VOC	37.92 V
IMP	8.07 A
VMP	30.96 V
KV (m/°C)	-0.346%/°C
Ki (m/°C)	+0.036%/°C
Kp (m/°C)	-0.47%/°C
NC	60

3. Resultados

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 dimensionan 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 integrarán las fuentes de energía y cargas al sistema de gestión energética para la optimización de su funcionamiento.

Para caracterizar la producción fotovoltaica consideramos inicialmente el potencial energético solar descrito en la Sección 2, el cual fue tomado a partir de mediciones durante un año. Se tiene entonces una insolación para la región de 5.0698, ecuación 2.

$$I_d = 5.0698 \frac{kWh}{m^2 \text{ dia}} \quad (2)$$

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 muestra el perfil de demanda para el mes de mayo (se eliminó el día inhábil de la serie de tiempo con fines de consistencia).

A partir de las mediciones del mes de mayor consumo energético se puede obtener una estimación la carga energética mensual, ecuaciones 3 y 4.

$$E_{carga} = \left(\int P(t) dt \right) \left(\frac{1h}{12 \text{muestras}} \right) \quad (3)$$

$$E_{carga} = 6,190 \text{ kWh /mes} \quad (4)$$

Para poder satisfacer esta demanda es necesario una instalación fotovoltaica capaz de generar 206.32 kWh diariamente. Al considerar la insolación promedio de $5.0698 \frac{kWh}{m^2 \text{ dia}}$ se puede calcular la potencia fotovoltaica instalada con paneles

de 250 W de potencia, eficiencia de 15.9 % y un área de 1.63 m² como en las ecuaciones 5 y 6.

$$Pot_{PV} = \left(5.0698 \frac{kWh}{m^2 \text{ día}}\right) (1.63 m^2) (0.153) \quad (5)$$

$$Pot_{PV} = 1.2644 \frac{kWh}{\text{día panel}} \quad (6)$$




Figura 2 Potencia de la carga para mayo con muestras cada 5 minutos.

De donde el número de módulos fotovoltaicos necesarios en la instalación fotovoltaica está dado por las ecuaciones 7 y 8.

$$\#módulos = \frac{Potencia_{carga}}{Pot_{PV}} \quad (7)$$

$$= \frac{206.32 \frac{kWh}{\text{día}}}{1.2644 \frac{kWh}{\text{día panel}}} = 163.17 \text{ módulos} \quad (8)$$

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 minutos.

En condiciones normales de operación, bajo una insolación de 6.1397 kWh/m^2 correspondiente al mes de abril (figura 3), la planta fotovoltaica debería producir 1286.19 kWh, ecuaciones 9 y 10.

$$E_{PV} = \left(6.1397 \frac{\text{kWh}}{\text{m}^2 \text{ dia}}\right) \left(1.63 \frac{\text{m}^2}{\text{módulo}}\right) (0.153)(28 \text{ módulos})(30 \text{ dias}) \quad (9)$$

$$E_{PV} = 1286.19 \text{ kWh} \quad (10)$$




Figura 3 Potencia fotovoltaica generada para mes de abril en una instalación de 7 kW.

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 (figura 4). 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 31.48 kWh, ver ecuaciones 11 y 12.

$$E_{PV} = \left(4.509 \frac{kWh}{m^2 \text{ dia}}\right) \left(1.63 \frac{m^2}{\text{módulo}}\right) (0.153) (28 \text{ módulos}) \quad (11)$$

$$E_{PV} = 31.48 \text{ kWh} \quad (12)$$

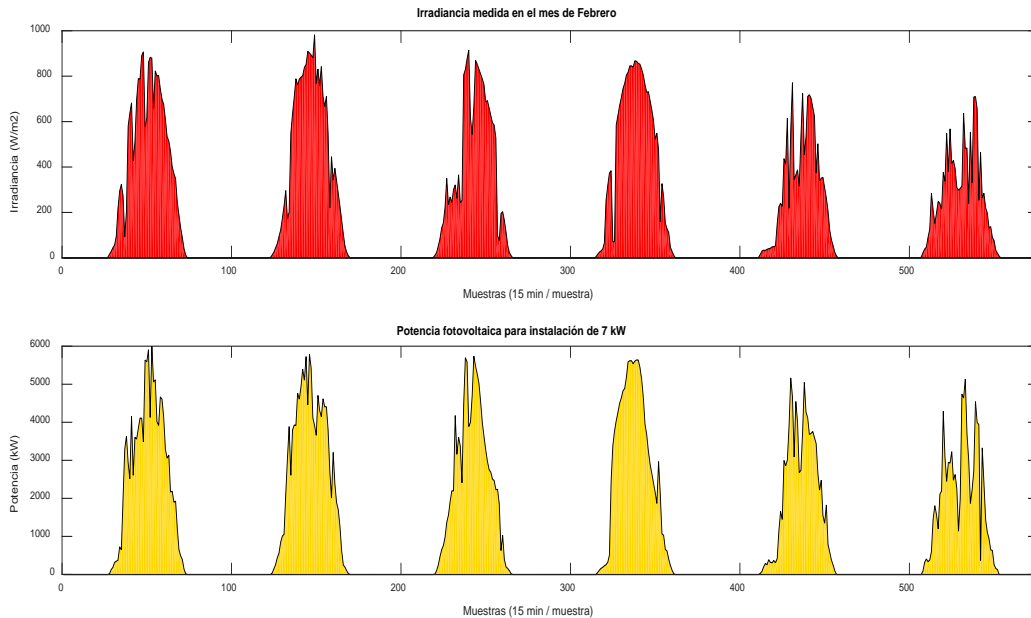


Figura 4 Potencia fotovoltaica generada para mes de febrero en una instalación de 4 kW.

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.

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 módulos de 250 W, los cuales se pueden conectar a 4 inversores Fronius de 11.4 kW.

Es posible estimar la producción de Hidrógeno por parte del electrolizador a partir de la predicción de generación fotovoltaica de la red neuronal. Para este proyecto se propone utilizar el modelo presentado en [15] 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 5 muestra el diagrama en Simulink para la predicción de producción de hidrógeno por el electrolizador.




Figura 5 Modelo en Simulink de electrolizador de 26 kW.

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 antes de ser procesados por la red y la salida de la red es escalada para obtener los valores reales.

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} .

4. Discusión de resultados

La figura 6 muestra que la predicción de producción de energía fotovoltaica se realiza con éxito con un buen horizonte de predicción y un error cuadrático medio $E=0.00078$.




Figura 6 Predicción de la generación fotovoltaica.

La figura 7 muestra que la predicción de la demanda energética se realiza con éxito con un buen horizonte de predicción y un error cuadrático medio $E=0.00012$.

De la figura 7 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.




Figura 7 Predicción de la demanda energética.

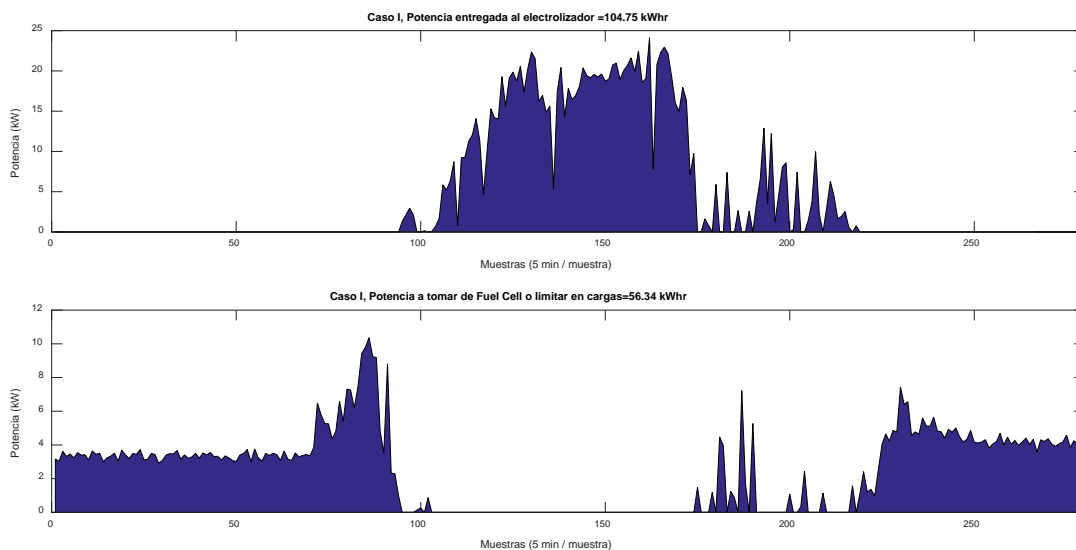


Figura 8 Potencias entregada al electrolizador y a demandar de la celda de combustible.

El excedente de energía es almacenado en forma de hidrógeno (eficiencia del 75% del electrolizador) y será utilizada por la celda de combustible (eficiencia del 40%) cuando la instalación fotovoltaica deje satisfacer la demanda. 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.

5. Conclusiones

En este trabajo se utilizan herramientas de inteligencia computacional para mejorar la operación de una red eléctrica inteligente. En particular se aplican redes neuronales artificiales para la predicción de la generación de potencia de instalaciones fotovoltaicas, demanda de edificios, utilizando redes neuronales recurrentes de alto orden.

La microred eléctrica inteligente, diseñada para trabajar en un bus de DC, está compuesta de las siguientes cargas principales: Sistema de generación fotovoltaica de 44 kW, Electrolizador alcalino de 26 kW ,7 bar y Celda de combustible de 7.5 kW a 24 VDC. Como condición de almacenamiento en el tanque de hidrógeno se especifica que al menos existan almacenados 0.1 kg de H₂.

Entre las principales aportaciones de este trabajo es el diseño de un modelo basado en redes neuronales para estimar la generación de potencia de un arreglo de paneles fotovoltaicos a partir de las condiciones ambientales y de irradiación. El error de aproximación de la red neuronal satisface los criterios de diseño y asegura una excelente aproximación con respecto a una base de datos obtenida de manera experimental.

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. La principal ventaja del esquema presentado 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.

6. Bibliografía y Referencias

- [1] NREL, Distributed Generation Renewable Energy Estimate of Costs. http://www.nrel.gov/analysis/tech_lcoe_re_cost_est.html#biblio. 2016.

- [2] Y. Hidaka, y K. Kawahara “Modeling of a hybrid system of photovoltaic and fuel cell for operational strategy in residential use”, 47th International Universities Power Engineering Conference (UPEC). London. 2012.
- [3] M. Osswald, “Experience with zero emission hybrid systems solar, wind, batteries and fuel cells for off-grid base stations”. Telecommunications Energy Conference 'Smart Power and Efficiency' (INTELEC), Proceedings of 2013 35th International. 2013. Pp. 1-5.
- [4] C. Nayar, S. Philips, “Novel wind/diesel/battery hybrid energy system”; Solar Energy Elsevier Science Ltd. Vol. 51. No. 1. 1993. Pp 65-78.
- [5] L. Ricalde, J. G. Catzin, A. Alanis, E. Sanchez, Time Series Forecasting via a Higher Order Neural Network trained with the Extended Kalman Filter for Smart Grid Applications, Artificial Higher Order Neural Networks for Modeling and Simulation. 2014. M. Zhang (Ed). IGI Global. Pp. 254-274
- [6] T. Henning, V. Gregor, “Towards a smart home energy management system - A dynamic programming approach”. Senior Member, IEEE. 2011.
- [7] T. Ishida, “Self-organization model for the energy cluster formation with distributed energy network”. IEEE Computational Intelligence Applications in Smart Grid (CIASG). 2013.
- [8] B. Marion, M. Anderberg, “PVWATTS -- An Online Performance Calculator for Grid-Connected PV Systems”. Proceedings SES Solar 2000 Conference, Madison, WI. 2000.
- [9] D. King, S. Gonzalez, G. Galbraith, W. Boyson, “Performance Model for Grid-Connected Photovoltaic Inverters”. SAND2007-5036. Sandia National Laboratories. 2007.
- [10] M. Osswald, “Experience with zero emission hybrid systems solar, wind, batteries and fuel cells for off-grid base stations”. Telecommunications Energy Conference 'Smart Power and Efficiency' (INTELEC), Proceedings of 2013 35th International. 2013. Pp. 1-5.
- [11] A. Alanís, L. Ricalde y E. N. Sánchez “High Order Neural Networks for Wind Speed Time Series Prediction”. Proceedings of the IEEE International Joint Conference on Neural Networks, Atlanta, Georgia, USA. 2009. Pp. 76-80.

- [12] L. Ricalde, Inverse Optimal Adaptive Recurrent Neural Control with Constrained. 2005. Tesis de doctorado, Centro de Investigación y de Estudios Avanzados (CINVESTAV) del Instituto Politécnico Nacional (IPN) Unidad Guadalajara. Guadalajara, México.
- [13] T. Holtschneider, I. Erlich, "Optimization of Electricity Pricing Considering Neural Network based Model of Consumers Demand Response". IEEE Computational Intelligence Applications in Smart Grid (CIASG). 2013. Pp. 154-160.
- [14] S. Rahman, K. Tam, "A feasibility study of photovoltaic-fuel cell hybrid energy system". Electrical Engineering Department Virginia Tech, Blacksburg. VA 24061. USA, IEEE Transactions on Energy Conversion. Vol. 3. No. 1. 1988.
- [15] L. Cao, "Practical method for determining the minimum embedding dimension of a scalar time series". Physica D: Nonlinear Phenomena. Vol. 110. No. 1. 1997. Pp. 43-50.

7. Autores

Ing. Erika H. Rubio Cámara recibió el título de Ingeniero Mecánico, del Instituto Tecnológico de Mérida, Yucatán, México, en 2012. Actualmente es estudiante de la Maestría en Ciencias en Energías Renovables del Centro de Investigación Científica de Yucatán. Fue profesora del programa de Ingeniería Mecatrónica del Centro de Estudios Superiores Francisco de Montejo, en 2013 y 2014, en Valladolid, Yucatán.

Dr. Luis C. Ordoñez López recibió el título de Ingeniero Químico de la Universidad Nacional Autónoma de México (UNAM) en 1998, la Maestría en la Facultad de Química, UNAM y el doctorado en el Centro de Investigación en Energía, UNAM, en 2006. Actualmente es Investigador Asociado C de la Unidad de Energía Renovable en el Centro de Investigación Científica de Yucatán (CICY). Sus líneas de investigación son: desarrollo de nuevos materiales electrocatalíticos para celdas de combustible de alcohol directo, electrólisis en sistemas de membrana de intercambio iónico y oxidación electroquímica de compuestos

no biodegradables. Ha publicado varios artículos científicos y es miembro del Sistema Nacional de Investigadores de México (SNI-1).

Dr. Luis J. Ricalde Castellanos recibió el título de Ingeniero Mecánico del Instituto Tecnológico de Mérida, Yucatán, México en 1999, la Maestría en Control Automático y el doctorado en Ciencias de la Ingeniería Eléctrica del CINVESTAV-IPN (Centro de Investigación y Estudios Avanzados del Instituto Politécnico Nacional), Guadalajara, México, en 2001 y 2005. Desde 2007, ha estado con la Universidad Autónoma de Yucatán (UADY) como profesor investigador del programa de posgrado en Ingeniería opción Energías Renovables. Su interés de investigación es el control neuronal no lineal, las redes eléctricas inteligentes, sistemas de generación de energía fotovoltaica y eólica. Se le concedió el Premio del Arturo Rosenblueth en 2005 y es miembro del Sistema Nacional de Investigadores de México (SNI-1).

Emmanuel de la Cruz May, obtuvo el título de Ingeniero en Mecatrónica de la Universidad del Valle de México, Campus Mérida en 2013. Actualmente está finalizando sus estudios de posgrado en Energías Renovables en la Facultad de Ingeniería de la UADY. Sus áreas de interés son la instrumentación electrónica y las redes eléctricas inteligentes.

M. I. Ricardo J. Peón Escalante obtuvo su grado de Maestro en Ingeniería Mecánica especialidad en diseño mecánico por la Universidad Nacional Autónoma de México y su área de investigación es síntesis óptima de sistemas mecánicos. Desde 2006, ha estado con la Universidad Autónoma de Yucatán (UADY) como profesor del programa de Ingeniería Mecatrónica.