

Pronóstico de la Demanda Diaria del Sistema Nacional Interconectado Utilizando Redes Neuronales

Oscullo José ¹; Haro Lenin ²

¹Escuela Politécnica Nacional, Facultad de Ingeniería Eléctrica y Electrónica, Quito, Ecuador

² Operador Nacional de Electricidad CENACE, Quito, Ecuador

Resumen: Un adecuado pronóstico de la demanda de un sistema eléctrico de potencia (SEP) es el primer paso en la determinación de las características de la calidad del servicio eléctrico proporcionado al consumidor, constituyéndose como uno de los requisitos más importantes para la planificación de la operación económica en niveles de calidad óptimos para el SEP.

Para la operación horaria de un SEP, contar de forma anticipada con la demanda lo más ajustada a los requerimientos reales de los consumidores, con lo que se alcance un adecuado control en el balance entre la generación ofertada por las centrales de generación y la carga demandada por los usuarios en cada instante de la operación del SEP, y así de esta forma asegurar el abastecimiento del producto "energía eléctrica" con estándares de calidad para cada usuario del servicio eléctrico.

Existe varias metodologías adoptadas por los SEP para obtener el pronóstico, este trabajo presenta un modelo mediante el uso de una red neural, la cual permita obtener el pronóstico de la demanda; en la cual se utiliza modelos no lineales eficientes que poseen la capacidad de aprender, identificar y aproximar las características de una serie de datos.

Para evaluar el desempeño del modelo se ha implementado un modelo en MATLAB®, que utiliza datos horarios de demanda del Sistema Nacional Interconectado (SNI) para un día laborable, uno de fin de semana y un día de feriado; a los cuales se aplicó dos métodos de entrenamiento a la red neural con el fin de obtener el pronóstico de la demanda. Mediante la optimización de la función de adaptabilidad de la red neural a la cual se le aplica dos técnicas de optimización de primero y segundo orden.

Palabras clave: Operación de SEP, demanda eléctrica, redes neuronales, optimización, pronóstico.

Forecast daily demand of the National Interconnected System Using Neural Networks

Abstract: Proper projection of demand for electric power system (SEP) is the first step in determining the characteristics of the quality of electricity service provided to the consumer, becoming one of the most important requirements for the planning of economic operation optimal levels of quality for the SEP.

For the time operating a SEP, tell in advance with the demand as closely to the real needs of consumers, so that adequate control on the balance between the generation offered by the generation plants and the required load is reached by users at every moment of the operation of SEP, and so thus ensuring the supply of the product "electricity" quality standards for each user of electricity. There are several methodologies adopted by the SEP for the projection, this paper presents a model using a neural network, which allows to obtain the projected demand; in which efficient nonlinear models that have the capacity to learn, identify and approximate the characteristics of a data set is used.

To evaluate the performance of the model is implemented in MATLAB® model that uses data demand schedules the National Interconnected System (SNI) for a weekday, one weekend and one-day holiday; to which two methods of training the neural network in order to obtain the demand forecast was implemented. By optimizing the adaptability function of the neural network to which it is applied two optimization techniques first and second order.

Keywords: SEP operation, power demand, neural networks, optimization, projection.

jose.oscullo@epn.edu.ec

Recibido: 21/10/2015

Aceptado: 11/05/2016

Publicado: 30/09/2016

1. INTRODUCCIÓN

La demanda eléctrica es el conjunto de una serie de valores obtenidos en unidades discretas de tiempo “*serie temporal*”. Para su análisis existe muchas técnicas, siendo las series de tiempo las más utilizadas para obtener el pronóstico; más en la práctica esta técnica considera únicamente las variaciones de la serie diaria de la demanda y no las características de los datos horarios (Freeman et al, 2010).

Si bien el pronóstico de la demanda de energía eléctrica es un tema ampliamente tratado a través de diferentes metodologías, más para el caso de la demanda en el corto plazo, el mismo que se considera como horizonte de tiempo desde una hora hasta un día, que es el requerimiento de los Operadores Técnicos de un SEP y cada día de la semana la demanda presenta características particulares, las mismas que son dinámicas y dependen de la estación, actividades de la sociedad lo que generan distintos patrones de comportamiento.

Para considerar estas características de la demanda eléctrica se han llevado adelante algunos trabajos aplicando herramientas de inteligencia artificial en el pronóstico de la demanda eléctrica. De acuerdo con Herrera L (2007), utiliza la modelación cualitativa-cuantitativa a través del razonamiento inductivo Fuzzy (FIR) con el que se obtiene el pronóstico a partir del último dato real agregado, con el fin de establecer las desviaciones de la demanda programada versus la real.

Ortiz p (2011), desarrolla una metodología para el pronóstico de la demanda eléctrica a corto plazo empleando una red neuronal de retropropagación con el mínimo de capas y neuronas a fin de considerar el cambio de estacionalidad que determina la curva de demanda. Mohamed et al (1996) presenta una descripción de la aplicación de RN en los sistemas eléctricos de potencia en varios temas como el control y reconocimiento de patrones.

Contar con un pronóstico de la demanda eléctrica diaria en períodos horarios en un SEP lo más ajustada a la realidad del consumo de los usuarios; permite planificar de manera eficiente el uso de los recursos de generación, transmisión y distribución disponibles para lograr estándares de calidad en el abastecimiento eléctrico.

Para el caso de la demanda eléctrica del SNI, que es la sumatoria de los consumos individuales los mismos dependen de los hábitos de cada consumidor por lo que estos no muestran regularidad, esta situación hace necesario desarrollar pronósticos más ajustados al consumo real; para alcanzar aquello se hace necesario considerar las variaciones intrínsecas que dependen de las actividades de los usuarios. Si el pronóstico considera la influencia de dichas variaciones obtenidas de la serie de la demanda de los días anteriores, distribuidos en días laborables, fines de semana, o feriados, establece un tipo especial de series de

tiempo que poseen relaciones no lineales entre sí, esta particularidad puede ser analizada por medio de las *Redes Neuronales* (RN) (Kovács, 1996).

El país se encuentra experimentando un crecimiento en su demanda eléctrica importante debido a las diferentes programas y proyectos para el cambio de la matriz energética, que impulsa la industrialización de ciertas actividades de la sociedad como por ejemplo el programa de cocción eficiente “cocinas de inducción” (Vicepresidencia de la República, (2015); Ministerio Coordinador de Sectores Estratégicos (MICSE), 2014), los cuales crean escenarios complejos para la pronóstico de la demanda eléctrica, por lo que se hace indispensable tener una pronóstico lo más ajustado, que permita mantener los niveles de reserva del sistema eléctrico dentro de los rangos establecidos garantizando el suministro eléctrico con calidad y confiabilidad, dentro de las investigaciones que se han realizado se ha establecido que las RN son modelos no lineales eficientes, las cuales tienen la capacidad de aprender, identificar y aproximar las características de una serie temporal, esto permite simular las relaciones no lineales e intrínsecas de los datos que componen dicha serie. (Haykin, 1999)

2. METODOLOGÍA

El pronóstico para cada una de las 24 horas del día, se constituye en parte de la planificación de corto plazo para la operación del SEP. Se la realiza con antelación de algunas horas para lo cual es importante mencionar que la misma constituye la información inicial para la toma de decisiones dentro de la planificación de la operación del SEP; que en conjunto permite considerar las variaciones técnicas y energéticas en el sistema eléctrico. Así, las decisiones asumidas para el abastecimiento de la demanda de corto plazo a través de datos más confiables generan economías considerables, debido al despacho de las diferentes unidades y centrales de generación.

Como la demanda del sistema eléctrico es la suma de todas las demandas individuales en cada barra, ésta es altamente variable debido a los diferentes usos de la energía por cada usuario, así, el reconocimiento de los factores que afectan el perfil de la demanda permite obtener una mejor proyección.

Entre los principales factores se encuentran (Jones, 2005):

- Económico: influenciados directamente por la actividad industrial, nivel de consumo, poder adquisitivo, etc.
- Temporal: presente por los efectos estacionales, días laborables, días fines de semana, días especiales (feriados).
- Eventos aleatorios: debido a la presencia de un gran número de factores individuales en la demanda; como por ejemplo huelgas, programas especiales de televisión cuya ocurrencia es conocida a priori, más su efecto sobre la carga es incierto.

De manera general la red neural debe aprender todos estos factores intrínsecos en el comportamiento de la demanda, estas características han permitido la utilización de las RN. Debido a que en el proceso la relación de los datos con el modelo no está explícito, el mismo es obtenido utilizándose únicamente los valores de entrada-salida de la red en intervalos regulares de tiempo. Otro factor favorable es la no limitación en el número de variables de entrada. (George, 2008)

Una RN es el conjunto formado por la interacción de varias unidades denominadas "neuronios" que en la naturaleza presentan una estructura como se muestra en la Figura 1, inspirada en las neuronas humanas, activándose de acuerdo a el nivel de una señal de entrada y generando una señal de salida, así por medio de una alta interconexión de los neuronios se obtiene la interpretación de las relaciones existentes en la serie de datos donde la fuerza de cada interconexión indica el nivel de aprendizaje de la red. (Floreano et al, 2008)

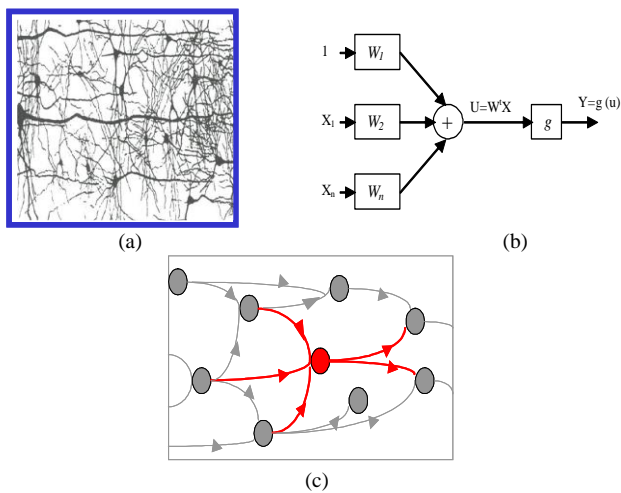


Figura 1. (a) Neuronas humanas (b) Neuronio teórico (c) Red Neural teórica

Para obtener la identificación de las relaciones existentes entre los diferentes datos, la red se conforma en una distribución con un número determinado de neuronios, la cual se denomina topología.

La topología escogida es una red de tres capas a saber (Floreano et al, 2008):

- Capada de entrada; neuronios para la lectura de los datos de la serie.
- Capada intermediaria; neuronios para la determinación de la relación no-lineal de los datos de la serie.
- Capada de salida; neuronios que generan el pronóstico de la demanda de las 24 horas del día analizado.

Esta topología escogida se denomina red multilayer perceptron (MLP), siendo su configuración como se muestra en la Figura 2 (Kovács, 1996; Jacek, 1992). Los

neuronios de la camada de entrada dependen del número de valores considerados de acuerdo a la correlación que poseen con la serie a ser pronosticada, mientras, los neuronios de la camada intermediaria dependen del nivel de interacción deseado [8]. De acuerdo a las interconexiones realizadas, es necesario, considerar que cada interconexión constituye una vía de transferencia de efectos positivos o negativos para cada valor ingresado en la red, por lo que, este número no debe ser ni muy pequeño ni muy grande sino ajustado de acuerdo a las características de cada serie.




Figura 2. Red Multilayer Perceptron (MLP)

La función que permite indicar el nivel de activación de cada neuronio se muestra en la Figura 3, la misma es tanh (x) su influencia es determinada de acuerdo a los pesos w_{ij} , siendo estos los que ponderan cada conexión de los neuronios, con el conjunto de entrenamiento entrada-salida de la red, este método de entrenamiento se denomina *Backpropagation*. (Jacek, 1992)




Figura 3. Función de activación de un neuronio

La regla de actualización de los pesos Δw_{ij} se obtiene por medio de la minimización del error entre los datos de entrada y la salida estimada, es decir, la propagación del error "Backpropagation". A partir de un punto inicial x_0 , se propaga esta información en la red obteniéndose un nuevo punto x_i , en este se actualiza los pesos w_{ij} este sencillo mecanismo es realizado hasta satisfacer un criterio de parada. La actualización de los pesos se la puede realizar por medio de métodos matemáticos de primer orden (gradiente) y segundo orden (Hessiana). (Haykin, 1999)

La habilidad para aprender de la RN, depende de las características de la serie y de la calidad de los datos ingresados en la red para su entrenamiento. Para la utilización de los datos en la RN deben ser normalizados en una banda adecuada siendo la seleccionada en el rango entre -1 y 1. Así, la normalización utilizada en la RN se indica en la Ecuación (1):

$$x_{in} = 2 \frac{x_{in} - x_{min}^i}{x_{max}^i - x_{min}^i} - 1 \quad (1)$$

Donde:

x_{min}^i es el mínimo valor i -ésimo del vector de datos.
 x_{max}^i es el máximo valor i -ésimo del vector de datos.

La normalización es importante dado a que uno o más neuronios pueden presentar valores de activación muy elevados y otros valores muy bajos esto puede llevar a un desbalance en la red, afectando la convergencia adecuada de la red. (George, 2008)

La función objetivo a ser minimizada por la red neural se muestra en la Ecuación (2); mediante la cual se determina el grado de convergencia de la red. A través de cada dato horario del pronóstico de la demanda la red va extrayendo la información del comportamiento del consumo de energía eléctrica de cada día analizado, la convergencia del entrenamiento se establece por medio del error cuadrático medio de la función objetivo. (Haykin, 1999)

$$SSE = \frac{1}{2} \sum_{i=1}^n (y(w) - yd)^2 \quad (2)$$

A continuación, se presenta el algoritmo de entrenamiento de la red neural donde se asume lo siguiente (Kovács, 1996):

- Conjunto de datos de entrada-salida normalizados.
- Una misma función de activación para todos los neuronios diferenciable.
- La función objetivo a ser minimizada SSE.
- Número de neuronios de la camada intermediaria fijos.
- Inicialización del conjunto de pesos w_{ij} de la red, aleatoriamente con una distribución uniforme en el intervalo (-0.6, +0.6)

En la Figura 4, se muestra un neuronio en el cual los únicos parámetros ajustables son los pesos w . Si se considera un estado inicial w_0 , el estado final alcanzado será w_f de tal que para un determinado conjunto de datos de entrada $(x_i, yd_i)_{i=1}^n$, la respuesta del neuronio al valor más próximo es obtenido por el entrenamiento con los datos yd_i , si en el mismo se ingresa los valores x_i .




Figura 4. Neuronio tipo perceptron

Las relaciones para el neuronio tipo perceptron se presentan en la Ecuación (3):

$$\begin{aligned} x &= [1 \ x_1 \dots \ x_n] \\ w &= [w_0 \ w_1 \dots \ w_n] \\ u(w) &= W^T x = \sum w_i x_i \\ y(w) &= g(u(w)) \end{aligned} \quad (3)$$

Considerando las expresiones de la Ecuación (3) en la Ecuación (2) del error cuadrático medio; se obtiene la superficie de error de acuerdo a la Ecuación (4): (Freman, 2010)

$$J(w) = \sum_{i=1}^n \frac{1}{2} (y_i(w) - yd_i)^2 = \sum_{i=1}^n \frac{1}{2} (g(u_i(w)) - yd_i)^2 = \sum_{i=1}^n J_i(w) \quad (4)$$

La Ecuación (4) constituye la función objetivo a ser minimizada SSE , no existe una única solución para este problema de optimización $\min_w J(w)$, por lo que debe recurrirse a un proceso de búsqueda iterativa.

Para determinar este proceso es necesario establecer una secuencia de direcciones de ajuste que conduzca desde el estado w_0 al estado w_f mediante esta información obtenida al aplicar el gradiente y/o la Hessiana de la función SSE respecto a los pesos w_i , como lo establece la Ecuación (5). (Freeman, 2008)

$$\frac{\partial J}{\partial w_i} = \frac{\partial}{\partial w_i} \left[\sum_{i=1}^n J_i(w) \right] = \sum_{i=1}^n \frac{\partial J_i}{\partial g(u_i(w))} \cdot \frac{\partial g(u_i(w))}{\partial u_i(w)} \cdot \frac{\partial u_i(w)}{\partial w_i} \quad (5)$$

Mediante la Ecuación (5) se obtiene el vector gradiente calculado en el valor actual del vector w , de acuerdo a la Ecuación (6).

$$\nabla J(w) = \left[\frac{\partial J(w)}{\partial w_0} \quad \frac{\partial J(w)}{\partial w_1} \quad \dots \quad \frac{\partial J(w)}{\partial w_n} \right] \quad (6)$$

Con esta información se puede ajustar el vector peso w por medio de un paso α (tasa de aprendizaje) como se presenta en la de la Ecuación (7).

$$w_{k+1} = w_k - \alpha \cdot \nabla J(w_k) \quad (7)$$

Mediante lo indicado la obtención del pronóstico de la demanda por medio de la RN no es necesaria tener un conocimiento detallado de las complejas interrelaciones entre todos los parámetros que influyen la demanda, sino que la RN tiene la libertad de escoger valores adecuados que representen estas interrelaciones.

El desempeño de la RN se determina por (Kovács, 1996):

- La convergencia del algoritmo de entrenamiento (actualización de los pesos) determina el grado de aprendizaje de la red.
- La topología de la red, de acuerdo al número de neuronios de la camada intermediaria
- La inicialización de variables determina la velocidad de convergencia.

3. RESULTADOS

El modelo propuesto de la red neural aplicada a la demanda de corto plazo del SNI se implementó en MATLAB® con una interface de EXCEL®, el mismo que permite obtener la estimación de la demanda para cada una de las 24 horas del día a proyectarse.

A continuación, se presentan los resultados obtenidos para un día laborable, uno de fin de semana y un día feriado, cuyos datos se obtienen del informe del CENACE 2014. (CENACE, 2014)

La Figura 5, muestra el pronóstico de la demanda para un día laborable, obtenidos mediante la optimización de la función SSE al resolver la Ecuación (4); utilizando los métodos de primer orden (gradiente) y el de segundo orden (Hessiana). Adicionalmente en la Tabla 1 se presenta el porcentaje de error máximo y mínimo para cada esquema de evaluación de la superficie de error respecto a la demanda real presentada en el SNI del día analizado. Se observa un mejor comportamiento al analizar el error mediante la Hessiana, que presenta un error máximo de 3,9%.

Ahora al utilizar el método del gradiente se presenta errores representativos para la demanda mínima y media. Pero en cualquiera de los casos el pronóstico es más ajustada a la obtenida por el método de las series temporales utilizada por el operador del SNI.

Tabla 1. Errores del pronóstico de un día laborable

Errores (%)	Gradiente	Hessiana	Serie Temporales
Máximo	7,6	3,9	9,1
Mínimo	0,8	0,1	1,9
Promedio	3,5	1,5	4,6




Figura 5. Pronóstico para el jueves 11 de diciembre de 2014.

En la Tabla 2 y la Figura 6 se presenta el error y el pronóstico para un día fin de semana.

Tabla 2. Errores del pronóstico de fin de semana

Errores (%)	Gradiente	Hessiana	Serie Temporales
Máximo	4,3	3,7	9,2
Mínimo	0,1	0,3	2,6
Promedio	2,2	1,6	3,6




Figura 6. Pronóstico para el domingo 14 de diciembre de 2014.

Para el caso de fin de semana se observa que el método del gradiente presenta errores significativos en el período de demanda media y máxima.

Al igual que en las proyecciones anteriores, en la Figura 7, se utilizó la RN para obtener el pronóstico para el caso de un día feriado mientras que en la Tabla 3 se muestra los errores determinados para este caso.

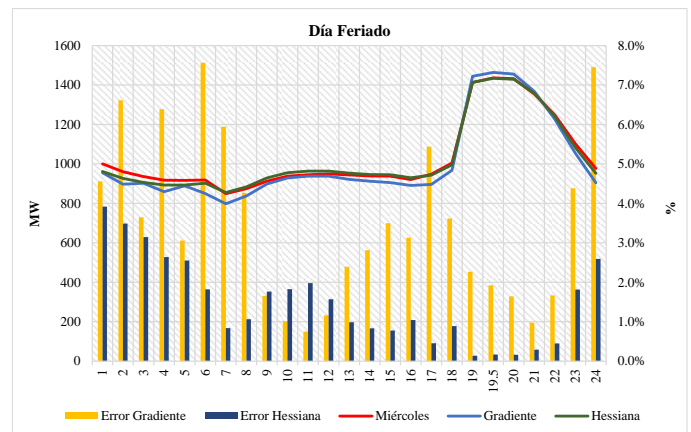


Figura 7. Pronóstico para el miércoles 1 de enero de 2014.

Tabla 3. Errores del pronóstico de fin de semana

Errores (%)	Gradiente	Hessiana	Serie Temporales
Máximo	6,1	3,4	8,1
Mínimo	0,1	0,1	2,3
Promedio	2,5	1,1	2,6

Para el caso del feriado se observa que el método del gradiente presenta errores significativos en todos los períodos de la demanda.

4. CONCLUSIONES

El uso del análisis de la superficie de error por medio de la Hessiana, muestra mejor característica ya que solicita a la RN realizar un ajuste más reducido, esta situación conlleva un mayor procesamiento de información.

El porcentaje de error mediante el análisis de la superficie de error por la Hessiana para el análisis del pronóstico de la demanda es inferior al 4%.

En el período de demanda máxima para los días laborables y feriados el método de la Hessiana presentó mejor desempeño, mientras que para el fin de semana los dos métodos se comportaron de manera semejante.

El desarrollo de una nueva metodología de pronóstico de demanda eléctrica, conlleva una mejor optimización en la programación del despacho de generación, conservando las características de seguridad y calidad en el suministro de energía permitiendo al SEP contar con la reserva rodante para condiciones de emergencia.

REFERENCIAS

- Floreano D, Mattiussi C. (2008) *Bio-Inspired Artificial Intelligence: Theories, Methods, and Technologies (Intelligent Robotics and Autonomous Agents)*. The MIT Press, pp. 70-95.
- Freeman, J. y Skapura, D. (2010) *Redes Neuronales: Algoritmos, aplicaciones y técnicas*, 1er ed. Copublicación de Addison-Wesley Iberoamerica, S.A. y Ediciones Diaz de Santos, pp. 230-175.
- George F (2008) *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*. Addison Wesley; (6th ed), pp. 20-75.
- Haykin, S. (1999) *Neural Networks: A Comprehensive Foundation*, (2nd ed) Prentice Hall, pp. 123–135.
- Herrera, L (2007) *Pronóstico de Demanda de muy Corto Plazo Utilizando Inteligencia Artificial*. Quito, Ecuador Tesis EPN.
- Jacek, M. (1992) *Introduction to Artificial Neural Networks*, West Publishing Company, New York, pp 18, 26-30,53-54.
- Jones Tim (2005) *A Application Programming*. Charles River Media; (2nd ed), pp. 30-55.
- Kovács Z. (1996) *Redes Neuras Artificias: Fundamentos y Aplicações* 2nd ed, São Paulo, pp. 64-93.
- Ministerio Coordinador de Sectores Estratégicos (MICSE) (2014). *Balance Energético Nacional Año base 2013*, Quito, Ecuador.
- Mohamed El-Sharkawi y Niebur (1996) *A Tutorial Course on Artificial Neural Networks with applications to power systems*, 1st ed., Power engineering society, Ed. Washintong D.C.: IEEE, vol. 1.
- Operador Nacional de Electricidad (CENACE) (2014) *Informe Anual*, pp. 1-12.
- Ortiz, P (2011) *Pronóstico de la Demanda de Energía Eléctrica a Corto Plazo Utilizando una Red Neuronal Óptima*. México D.F, México Tesis IPN.
- Vicepresidencia de la República (2015) *Estrategia Nacional Para el Cambio de la Matriz Productiva*, 1era ed, Quito, Ecuador.



Haro Estrella Lenin, nació en Ibarra, Ecuador, sus estudios secundarios los realizó en el Instituto Tecnológico Superior Central Técnico, recibió su título de ingeniero eléctrico en la Escuela Politécnica Nacional en septiembre de 2010, está desarrollando sus estudios en la Maestría en Eficiencia Energética en la Escuela Politécnica Nacional. Su campo de investigación se encuentra basado en el estudio de Energías Renovables, la incorporación de generación distribuida en los sistemas de potencia, estudios del impacto de la explotación de generación en el Sistema Nacional Interconectado de Ecuador.



Oscullo Lala José nació en Sangolquí, Ecuador, en 1971. Recibió su título de ingeniero eléctrico en la Escuela Politécnica Nacional en 1996, Master en ingeniería eléctrica de la Universidad Estatal de Campinas, Sao Paulo en 2002 y Magister en Dirección de Empresas de la Universidad Andina Simón Bolívar Sede Ecuador en 2008. Actualmente se desempeña como profesor titular del Departamento de Energía Eléctrica de la Facultad de Ingeniería Eléctrica y Electrónica de la Escuela Politécnica Nacional. Su campo de investigación se encuentra relacionado a la aplicación de sistemas expertos y financieros en sistemas eléctricos de potencia; análisis técnico, económico y financiero de la operación y expansión de sistemas eléctricos.