

## **Modelación y proyección de energía eléctrica mediante redes neuronales y simulación de Monte Carlo: Caso de estudio de México**

R. Luna & J. Rojas

R. Luna & J. Rojas

Universidad de Autónoma de Querétaro, Cerro de las Campanas S/N, Las Campanas, 76010 Santiago de Querétaro, Querétaro de Arteaga Departamento de Mantenimiento Industrial, Facultad de Ingeniería  
ricardo.luna.rubio@gmail.com.

M. Ramos.,V.Aguilera.,(eds.). Ciencias de la Ingeniería y Tecnología, Handbook -©ECORFAN- Valle de Santiago, Guanajuato, 2013.

## Abstract

In the present work is reported a theoretical-methodological framework, in which are presented alternatives for carried out accurate projections about the growth of the national electrical power demand, as well as for analyzing the integration of alternative energy sources into hybrid energy systems at customer or end user scale by using of stochastic modeling. For the projections of the national electrical power demand growth, a meta-heuristic approach is presented. This approach combines artificial neural networks modeling with Monte Carlo simulations. On the other hand, for the analysis of the alternative sources into hybrid energy systems at end user level, an approach where deterministic computational simulation models are combined with Monte Carlo simulations is proposed.

## 4 Introducción

El modelado y pronóstico de demanda de energía eléctrica juega un papel de vital importancia para los responsables de políticas energéticas y organizaciones relacionadas, tanto en países desarrollados como en países en desarrollo. Bajas estimaciones en el crecimiento de energía pueden traer como consecuencia un desabasto energético, lo cual trae implicaciones económicas serias para la nación; por otro lado, sobreestimaciones en el crecimiento de la demanda eléctrica traerá como consecuencia gastos innecesarios para aumentar la capacidad de abasto.

El pronóstico de la demanda de energía eléctrica requiere un marco teórico-metodológico que permita hacer frente a las múltiples variables no lineales que influyen en el crecimiento del sector eléctrico, de tal forma que sea posible interpretarlas y relacionarlas de la mejor manera con la demanda de energía en el futuro próximo, permitiendo de esta manera tomar mejores decisiones en la planeación de la capacidad energética requerida de manera precisa. Hoy en día, el modelado de energía eléctrica es un tema de gran interés para ingenieros y científicos preocupados por el problema de producción y consumo de energía (Egelioglu, Mohamad y Guven 2001, Zhou, Ang y Poh 2006, Ünler 2008).

Debido a lo antes mencionado, con la finalidad de predecir de manera precisa la demanda futura de energía eléctrica varias técnicas novedosas han sido reportadas durante la década pasada (Suganthi y Samuel 2011, Sözen y Arcaklioglu 2007). La relación entre consumo de energía e indicadores económicos, sociales y demográficos ha sido un tema ampliamente estudiado (Sözen y Arcaklioglu 2007). Kavaklioglu et al. (Kavaklioglu et al. 2009), utilizan RNA's para modelar y predecir el consumo de electricidad anual de Turquía, en su trabajo reportado consideran como variables independientes la población, PIB, importaciones y exportaciones. Mediante modelos de regresión, Bianco et al. (Bianco, Manca y Nardini 2009) modelan la relación entre el consumo de energía eléctrica e indicadores económicos y demográficos como PIB, PIB per cápita y población.

En México, la planeación del desarrollo del sector eléctrico es realizada año con año por la Comisión Federal de Electricidad (CFE), la cual, es llevada a cabo con base en una proyección que sobre el crecimiento de la demanda de energía eléctrica a nivel nacional. Con dicha proyección de crecimiento, se determina la nueva capacidad de generación de energía requerida para realizar el despacho esperado.

Los pronósticos de crecimiento de demanda energética se basan en una media aritmética y no consideran posibles variaciones en el producto interno bruto o en la población nacional, por lo que las proyecciones realizadas son lineales y difícilmente se aproximan a la realidad.

Por lo anterior, dentro del presente trabajo de investigación es planteado un marco teórico-metodológico basado en el uso de técnicas estocásticas, el cual, se propone como una alternativa para tareas propias de planeación y desarrollo del sector eléctrico nacional.

#### **4.1 Método**


Modelación de la demanda de energía eléctrica en México. Para la modelación y proyección de la energía eléctrica neta consumida, con base en la revisión de literatura realizada, se propone relacionar indicadores nacionales tales como, producto interno bruto (PIB), población (POB), tasa de desempleo (TDD) e importaciones y exportaciones de bienes y servicios (IBS y EBS respectivamente) con consumo neto de energía eléctrica (CNE) a nivel nacional.

Para dicha relación, son consideradas tres técnicas de modelación distinta: regresiones lineales múltiples, regresiones no lineales y redes neuronales artificiales. Para esta parte del estudio propone dividir en tres grandes etapas el análisis: modelado, validación y proyecciones. Una vez calibrados los modelos predeterminados, son evaluados en la etapa de validación, donde son puestos a prueba ante un nuevo conjunto de datos entrada-salida.

Para los procesos de modelación y validación es considerada la información comprendida entre los años 1980 y 2009. Con base en la modelación de información de expertos reportada dentro del marco teórico de la presente tesis, son caracterizadas mediante fdp PERT ( $F(U)$ ) las tasas de crecimiento que pudieran tener las variables de entrada a los modelos calibrados.

La metodología propuesta plantea lo siguiente. A partir de un valor inicial  $X_1$  (ver figura 4), una cadena de  $n$  valores futuros  $X_i$  de una variable  $x$  son calculados mediante el cálculo de una tasa de crecimiento obtenida mediante simulaciones de Monte Carlo, esto es mediante la generación de valores aleatorios  $U \in (0,1)$  evaluados en  $F^{-1}(U)$ .

**Figura 4** Cadena de transiciones para calcular los valores futuros  $X_i$ , dada una fdp de la tasa de crecimiento de la variable  $x$  y un número aleatorio  $U$



## 4.2 Resultados

Construcción del modelo de regresión lineal. Las variables independientes para el modelo de regresión lineal que predice la CNE de México son determinadas utilizando la técnica de regresión paso a paso o stepwise. El enfoque utilizado es el de selección de variables hacia adelante.

Los estadísticos empleados para determinar la adición de nuevas variables son el coeficiente de correlación, la desviación estándar estimada de los residuos o desviaciones alrededor del modelo y el error absoluto medio (EAM). En cuanto a la información de entrada utilizada para ajustar los parámetros del modelo de regresión fueron tomadas las primeras dos terceras partes del total de registros disponibles (1980-1999). El proceso iterativo para la construcción del modelo de regresión lineal es presentado a continuación y detallado paso a paso.

- a) Paso 1: Son obtenidos modelos de regresión con una variable de entrada, es decir, con la forma presentada en con  $n = 1$ . Para la variable independiente  $x_1$  luego del análisis presentado en la sección anterior, son considerados únicamente los indicadores PIB, POB, IBS y EBS. Resultados del proceso de calibración de modelos se encuentran resumidos en la Tabla. Como podemos ver, el modelo con mayor coeficiente de correlación y menor error es el que considera a la población como variable independiente.

**Tabla 4** resultados del proceso de calibración para los modelos lineales considerados en el paso 1

$x_1$	$\beta_0$	$\beta_1$	$r^2$	$\sigma$ residuos	EAM
PIB	-93.7278	4.66E-10	0.9136	8.71228	6.88463
POB	-152.201	3.0482E-06	0.977	4.49899	3.46148
IBS	59.3652	6.62E-10	0.8075	13.0038	8.60601
EBS	56.2309	7.14E-10	0.9028	9.24186	7.49587

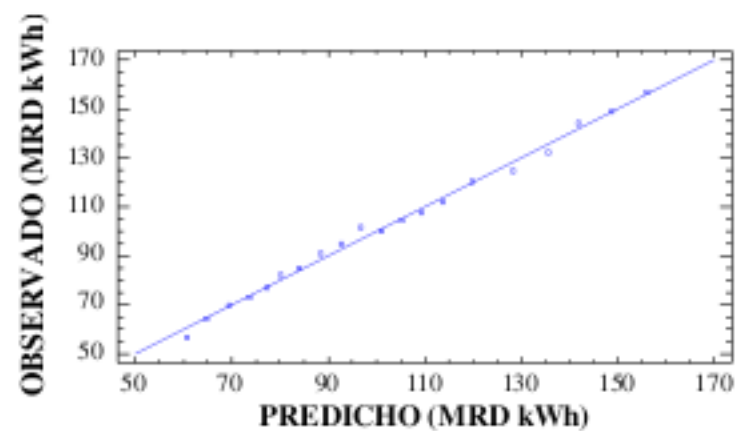
- b) Paso 2: Para el segundo paso de nuestro proceso iterativo para construir el modelo de regresión lineal, se evalúa el impacto de adicionar una segunda variable al mejor modelo obtenido en el paso anterior. Resultados del proceso de calibración de modelos correspondientes a esta segunda etapa de la construcción del modelo se encuentran resumidos en la Tabla. Como podemos apreciar, el modelo que considera como variables de entrada a la POB y a las EBS es el que reporta mejores resultados. Con esta segunda iteración y con el mejor modelo obtenido, se termina el proceso de construcción del modelo. Finalmente, son presentadas como resultado del proceso de construcción del modelo las gráficas 4 y 4.1.

**Tabla 4.1** Resultados del proceso de calibración para los modelos lineales considerados en el paso 2

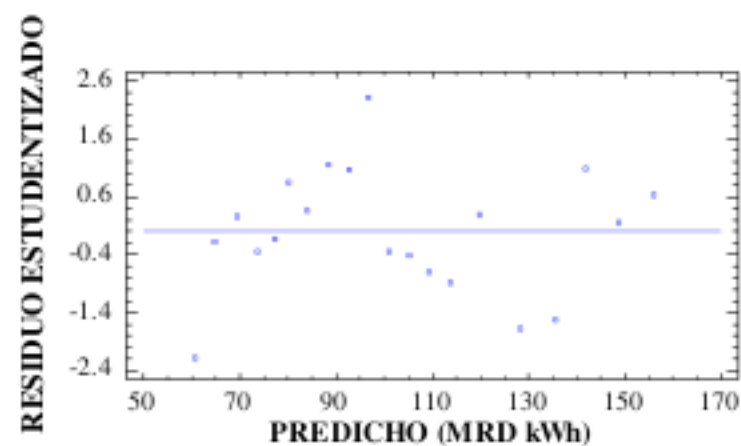
$x_1$	$x_2$	$\beta_0$	$\beta_1$	$\beta_2$	$r^2$	$\sigma$ residuos	EAM
POB	PIB	-144.324	2.4455E-06	1.01E-10	0.9816	4.13833	3.2562
POB	IBS	-124.118	2.6206E-06	1.17E-10	0.9831	3.96031	3.3610
POB	EBS	-95.4555	2.1899E-06	2.31E-10	0.9941	2.34494	1.7363

Resultados del modelo lineal construido (CNE = f(POB,EBS)).

**Gráfico 4** Gráfico de correlación



**Gráfico 4.1** Residuos estudentizados



Construcción del modelo de regresión no-lineal

De manera similar a la construcción de modelo de regresión lineal, son utilizados los mismos datos de entrada (1980-1999) y la misma metodología para la selección de variables independientes (stepwise). En cuanto al modelo no-lineal a calibrar, funciones exponenciales del tipo presentado en son calibradas. A continuación, el proceso de construcción del modelo es presentado paso a paso.

Paso 1: Son obtenidos modelos de regresión con una variable de entrada, es decir, con la forma presentada con  $n = 1$ . Al igual que para el modelo lineal, para la variable independiente  $x_1$  son considerados únicamente los indicadores PIB, POB, IBS y EBS.

Resultados del proceso de calibración de modelos se encuentran resumidos en la Tabla. Como podemos ver, el modelo con mayor coeficiente de correlación y menor error es el que considera a la población como variable independiente. Como podemos ver, la variable que mejor describe al CNE son las EBS, por lo tanto, seleccionamos esta variable y evaluamos el impacto de agregar una segunda variable en el paso siguiente.

**Tabla 4.2** Resultados del proceso de calibración para los modelos no-lineales considerados en el paso 1

$x_1$	$\beta_0$	$\beta_1$	$r^2$	$\sigma$ residuos	EAM
PIB	0.110793	0.255411	0.2240	26.1091	20.0294
POB	0.100452	0.380208	0.2773	25.1965	19.468
IBS	0.0417702	0.315199	0.7320	15.343	9.87123
EBS	0.0222778	0.340539	0.8711	10.64	8.48373


Paso 2: Se evalúa ahora el impacto de adicionar una segunda variable al mejor modelo obtenido en el paso anterior. Resultados del proceso de calibración de modelos correspondientes a esta segunda etapa de la construcción del modelo se encuentran resumidos en la tabla 4.3. Como podemos apreciar, el modelo que considera como variables de entrada a las EBS y a las IBS es el que reporta mejores resultados. Sin embargo, las estimaciones del modelo no mejoran significativamente respecto a los resultados del paso anterior. Esto es claro puesto que las IBS y las EBS reportaron una alta correlación en el análisis presentado en la Sección. Con esta segunda iteración se termina el proceso de construcción del modelo. Finalmente, son presentadas como resultado del proceso de construcción del modelo los gráficos 4.2 y 4.3. Como podemos ver en estas gráficas, los errores del modelo ajustado presentan una clara tendencia, ello indica que probablemente la precisión en las predicciones del modelo disminuya para realizar extrapolaciones para valores futuros.

**Tabla 4.3** Resultados del proceso de calibración para los modelos no-lineales considerados en el paso 2

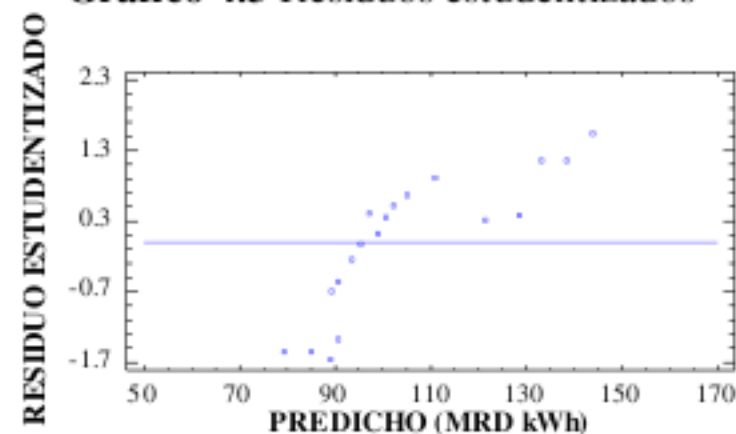
$x_1$	$x_2$	$\beta_0$	$\beta_1$	$\beta_2$	$r^2$	$\sigma$ residuos	EAM
EBS	PIB	0.0058774	0.311552	7.67E-02	0.8601	11.4078	8.77412
EBS	POB	0.00844525	0.304529	1.02E-01	0.8543	11.6411	8.97336
EBS	IBS	0.00661939	0.219597	1.70E-01	0.8997	9.65741	6.41097

Resultados del modelo no-lineal construido (CNE = f (EBS)).

**Grafico 4.2** Gráfico de correlación



**Grafico 4.3** Residuos estudentizados



Construcción del modelo de regresión no-lineal.

Finalmente, siguiendo con el mismo procedimiento de selección de variables es seleccionado un modelo basado en redes neuronales.

Paso 1: De manera inicial son calibrados redes neuronales del tipo perceptrón multicapa, con una entrada, una capa oculta de 3 neuronas y una capa de salida con una neurona. Para el proceso de entrenamiento fueron utilizados un coeficiente de aprendizaje de 0.5 y un coeficiente de momentum de 0.1. Resultados del proceso de entrenamiento se encuentran en la tabla siguiente.

**Tabla 4.4** Resultados del proceso de calibración para los modelos de redes neuronales considerados en el paso 1 para redes neuronales con una variable de entrada  $x_1$ , 3 neuronas en la capa oculta, coeficiente de aprendizaje de 0.5 y coeficiente de momentum de 0.1.

$x_1$	$r^2$	$\sigma_{residuos}$	EAM
PIB	0.9582	8.25548	6.69767
POB	0.9894	4.21930	3.40347
IBS	0.9015	12.48811	8.55047
EBS	0.9805	5.72181	4.75409

Como podemos ver, el modelo que considera como variable de entrada a la POB es el que reporta mejores estimaciones. El coeficiente de correlación es tan alto (0.9894) que se decide parar el proceso de construcción del modelo.

### 4.3 Discusión

Validación de los modelos seleccionados: Para validar los modelos seleccionados en la sección anterior, las estimaciones de los mismos ante el tercio restante de las variables de entrada (información del período 2000-2009) son evaluadas. Resultados de este proceso de validación son presentados a continuación.

**Tabla 4.5** Resultado del proceso de validación con los modelos seleccionados

$x_1$	$x_2$	$\beta_0$	$\beta_1$	$\beta_2$	$r^2$	$\sigma_{residuos}$	EAM
POB	EBS	-95.4555	2.1899E-06	2.31E-10	0.98706	4.85184	28.78109
EBS	-	0.0222778	0.340539	-	0.92498	9.01658	27.20426
POB	-	-	-	-	0.97820	4.11511	6.16342

Resultados del proceso de validación

**Gráfico 4.4** de correlación


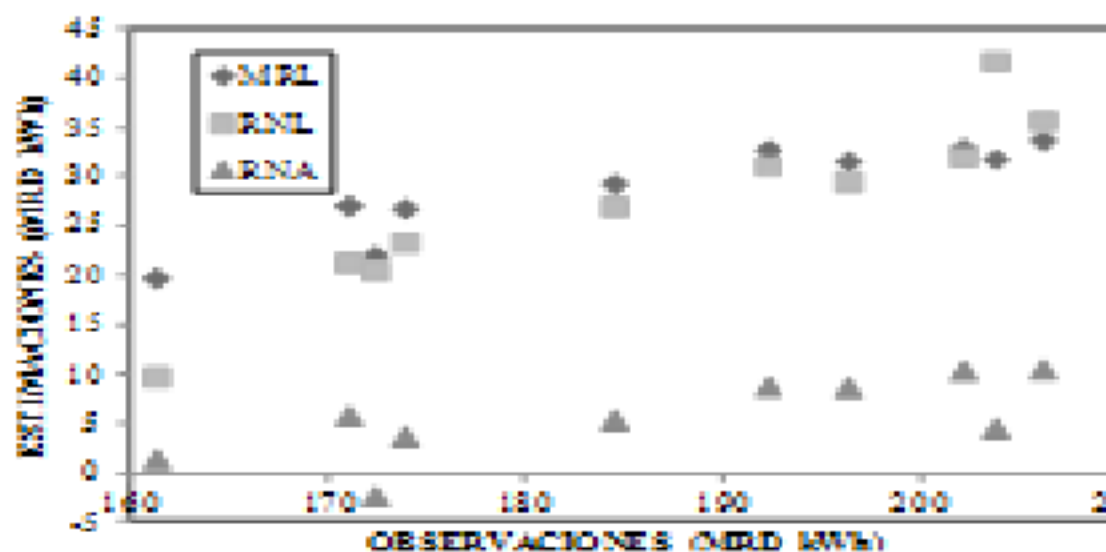


Gráfico 4.5 de residuales



Como podemos apreciar, es evidente que el modelo que mejores estimaciones realiza durante el proceso de validación es el modelo de redes neuronales artificiales, mientras que las estimaciones de los modelos MRL y RNL presentan una gran similitud entre sí. Adicional al análisis estadístico previo, es realizado un análisis de varianza (ANOVA). El ANOVA es utilizado para hacer un análisis de medias, esta técnica descompone la varianza de nuestros datos en dos componentes, esto es, un componente entre grupos o modelos y un componente dentro de grupos o modelos. El estadístico F, que en este caso es igual a 16.69 (ver Tabla ), es el resultado entre el estimado entre grupos y el estimado dentro de grupos. Dado que el valor P de la prueba de F es menor que 0.05, podemos afirmar que existe una diferencia significativa entre las medias de las 4 variables (valores reales, estimaciones MRL, RNL y RNA) con un nivel del 95% de confianza. Para determinar cuáles son las variables diferentes, es realizada una prueba de rangos múltiples.

**Tabla 4.6** de ANOVA entre los valores reales y las estimaciones hechas por el modelo MRL, RNL y ANN

Fuente	Suma de Cuadrados	Gl	Cuadrado Medio	Razón-F	Valor-P
Entre grupos	6497.81	3	2165.94	13.69	0.0000
Intra grupos	5694.06	36	158.168		
Total (Corr.)	12191.9	39			


Adicional al análisis de varianza, las medias de los valores reales, y las estimaciones hechas por el MRL, RNL y la RNA son examinadas. Para dicho análisis, un gráfico de medias es presentado en el grafico 4.6.

En el gráfico la media de cada muestra es presentada junto con un intervalo de incertidumbre, para este caso en particular, intervalos de menor diferencia significativa de Fisher son presentados.

Estos intervalos se construyen de manera tal que es posible seleccionar un par de muestras y declarar que sus medias son significativamente diferentes si los intervalos no se traslapan en la dirección vertical.

La posibilidad de declarar incorrectamente que dos muestras son diferentes con este método está ajustada a un 5%, haciendo que las comparaciones entre muchos pares de medias resulten erróneas en al menos un par con una probabilidad muy alta.

**Grafico 4.5** Gráfico de medias (intervalos de menor diferencia significativa de 95% de Fisher)



Como podemos ver en grafico 4.5, las estimaciones hechas por la RNL y la RNA son muy similares, mientras que las estimaciones que se acercan más a los valores reales son las estimaciones hechas por la RNA. Finalmente, una prueba de rangos múltiples es realizada con la finalidad de identificar grupos o diferencias significativas entre las estimaciones y los valores observados.

La tabla 4.6 muestra la diferencia significativa entre cada par de medias, el asterisco indica que estos pares de muestras presentan una diferencia significativa con un nivel de confianza de 95%. Por otro lado, en la tabla 4.7 se identifican 2 grupos homogéneos (según la alineación de las X's en columnas). El método empleado para discriminar entre las medias es el procedimiento de la diferencia mínima significativa de Fisher. Con este método existe un riesgo del 5% al decir que cada par de medias es significativamente diferente cuando la diferencia real es igual a 0.

**Tabla 4.6** Prueba de rangos múltiples (95% intervalos de menor diferencia significativa)

	Casos	Media (MRD kWh)	Grupos Homogéneos
VRL	10	157.563	X
VRNL	10	159.14	X
VANN	10	180.651	X
Real	10	186.344	X

**Tabla 4.7** Diferencias estimadas entre cada par de muestras


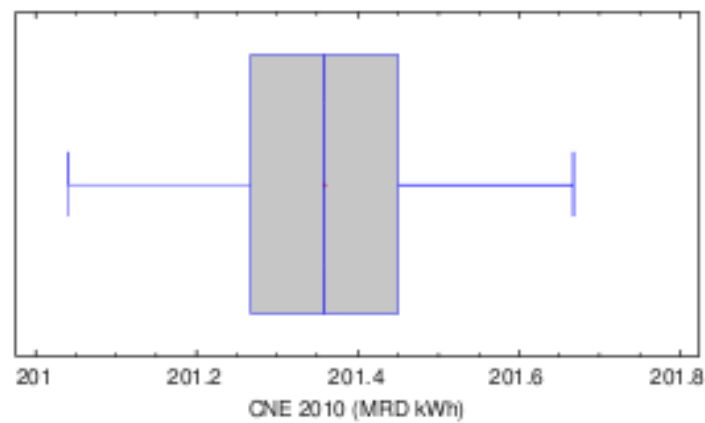

Contraste	Sig.	Diferencia (MRD kWh)	+/- Límites
Real - VRL	*	28.7811	11.4068
Real - VRNL	*	27.2043	11.4068
Real - VANN		5.69289	11.4068
VRL - VRNL		-1.57683	11.4068
VRL - VANN	*	-23.0882	11.4068
VRNL - VANN	*	-21.5114	11.4068

Indica una diferencia significativa




Con base en el análisis estadístico presentado en el proceso de validación, el modelo de RNA es seleccionado para combinarlo con las simulaciones de Monte Carlo para proyectar valores futuros del CNE.

Luego del proceso de validación de los modelos seleccionados, para realizar proyecciones en la demanda de energía eléctrica neta para México, fue seleccionado el modelo de RNA. Las variables de entrada de dicho modelo fueron proyectadas para los años 2010, 2012 y 2014 utilizando información disponible de expertos (CONAPO). Cada una de las variables de entrada fue caracterizada su probabilidad de ocurrencia para los años considerados utilizando funciones de distribución de probabilidad del tipo PERT. Luego de este proceso de caracterización de las variables de entrada al modelo de RNA, fueron realizadas simulaciones de Monte Carlo para generar valores de ocurrencia probables para todas las entradas al modelo. En total, fueron realizadas 10000 simulaciones, es decir, fueron creados 10000 distintos escenarios posibles de ocurrencia para cada una de las variables de interés, con dicha información fue alimentado el modelo RNA para generar la misma cantidad de escenarios probables en el crecimiento de la demanda de energía eléctrica para México. Resultados de las simulaciones son presentados en los gráficos 4.6, 4.7 y 4.8.


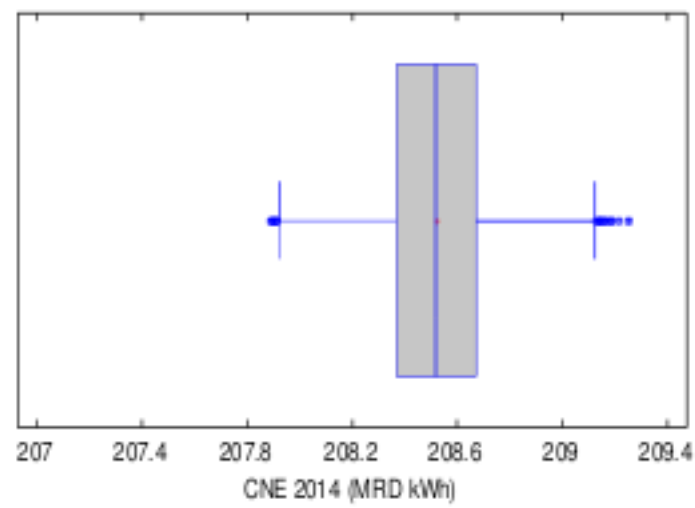

Proyecciones estimadas para el CNE (MRD kWh) correspondiente al 2010 (10000 simulaciones) con el modelo de RNA calibrado.

**Grafico 4.6** Gráfico de dispersión**Grafico 4.7** Gráfico de caja y ejes**Grafico 4.7** Fdp discreta (MRD kWh)

Proyecciones estimadas para el CNE (MRD kWh) correspondiente al 2012 (10000 simulaciones) con el modelo de RNA calibrado.

**Grafica 4.8** Gráfico de dispersión**Grafico 4.9** Gráfico de caja y ejes**Grafico 4.10** Fdp discreta (MRD kWh)

Proyecciones estimadas para el CNE (MRD kWh) correspondiente al 2014 (10000 simulaciones) con el modelo de RNA calibrado.

**Grafico 4.11** Gráfico de dispersión**Grafico 4.12** Gráfico de caja y ejes**Grafico 4.13** Fdp discreta (MRD kWh)

#### 4.4 Conclusiones

En el caso de estudio reportado se mostró una alternativa para proyectar el crecimiento de la capacidad instalada en la red eléctrica nacional mediante simulaciones de Monte Carlo. La propuesta metodológica reportada permite integrar la información de expertos de distintas áreas y combinarla con modelos determinísticos previamente calibrados, como resultado, las estimaciones realizadas consideran una gran cantidad de escenarios que siguen la información proporcionada por expertos y/o información histórica.

Lo anterior permite evaluar estadísticamente la incertidumbre inherente al fenómeno de interés. Respecto a las variables de entrada consideradas para predecir el consumo neto de energía, pudimos observar que todas a excepción de la TDD presentan una alta multicolinealidad entre ellas. El uso de un análisis de regresión paso a paso nos permitió seleccionar los indicadores que estimaran con mayor precisión el consumo neto de energía para cada una de las metodologías de modelado consideradas (MRL, RNL, y RNA). Para el caso de estudio reportado, se observó una alta relación entre la población y el consumo neto de energía eléctrica de México. Para la etapa de validación, los tres modelos calibrados reportaron altas precisiones; sin embargo, resultados demostraron la efectividad de las redes neuronales artificiales para estimar con mayor precisión la demanda de energía eléctrica para el caso de nuestro país.

#### 4.5 Referencias

- Cho, A. (2010). Energy's tricky tradeoffs. *Science*, 329(5993), 786-787.
- Connolly, D., Lund, H., Mathiesen, B., & Leahy, M. (2010). A review of computer tools for analysing the integration of renewable energy into various energy systems. *Applied Energy*, 87(4), 1059-1082.
- Del Río, P., & Burguillo, M. (2008). Assessing the impact of renewable energy deployment on local sustainability: Towards a theoretical framework. *Renewable and Sustainable Energy Reviews*, 12(5), 1325-1344.
- Dyer, C. (1996). Neural Networks. CS 540 Lecture Notes, (pp. Chapter 18.6.3 - 18.7).
- Eastin, J., Grundmann, R., & Prakash, A. (2010). The two limits debates: "Limits to Growth" and climate change. *Futures*.
- Floyd, J., & Zubevich, K. (2010). Linking foresight and sustainability: An integral approach. *Futures*, 42(1), 59-68.
- Hocaoglu, F., Gerek, O., & Kurban, M. (2009). The effect of model generated solar radiation data usage in hybrid (wind-PV) sizing studies. *Energy Conversion and Management*, 50(12), 2956-2963.

Hopfield, J. (1982). Neural networks and to physical systems with emergent collective computational abilities. *Proc Natl Acad Sci*, 79, 2554-2558.

Kaldellis, J., & Zafirakis, D. (2011). The wind energy (r)evolution: A short overview of a long history. *Renewable Energy*, 36(7), 1887-1901.

Kammen, D. M. (2010). 2020 visions. *Nature*, 463(7), 26-32.

Kolokotsa, D., Rovas, D., Kosmatopoulos, E., & Kalaitzakis, K. (2011). A roadmap towards intelligent net zero- and positive-energy buildings. *Solar Energy*, 85(12), 3067-3084.

Luna-Rubio, R., Herrera-Ruiz, G., Trejo-Perea, M., Vargas-Vázquez, D., & Ríos-Moreno, G. (2009). Lighting automatic control system for intelligent buildings. *International Review of Automatic Control*, 2(4), 469-476.

Luna-Rubio, R., Rojas-Renteria, J., Vazquez-Cruz, M., & Rodriguez-Resendiz, J. (In Process). Modeling and Forecasting of Electrical Net Consumption by Using Artificial Neural Networks and Monte Carlo Methods: Mexico's Case of Study. *Renewable Energies and Power Quality Journal*.

Luna-Rubio, R., Trejo-Perea, M., Vargaz-Vazquez, D., & Rios-Moreno, G. (In Press). Optimal sizing of renewable hybrids energy systems: A review of methodologies. *Solar Energy*.

Martínez-Durbán, M., Zarzalejo, L., Bosch, J., Rosiek, S., Polo, J., & Batlles, F. (2009). Estimation of global daily irradiation in complex topography zones using digital elevation models and meteosat images: Comparison of the results. *Energy Conversion and Management*, 50(9), 2233-2238 .

McCulloch, W., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5(4), 115-133.

Mellit, A., Kalogirou, S., Shaari, S., Salhi, H., & Hadj Arab, A. (2008). Methodology for predicting sequences of mean monthly clearness index and daily solar radiation data in remote areas: Application for sizing a stand-alone PV system. *Renewable Energy*, 33(7), 1570-1590.

Michalak, P., & Zimny, J. (2011). Wind energy development in the world, Europe and Poland from 1995 to 2009; current status and future perspectives. *Renewable and Sustainable Energy Reviews*, 15(5), 2330-2341.

Minsky, M., & Papert, S. (1969). *Perceptrons*. Cambridge, MA: MIT Press.

- Moslehi, K., & Kumar, R. (2010). A reliability perspective of the smart grid. *IEEE Transactions on Smart Grids*, 1(1), 57-64.
- Paliwal, M., & Kumar, U. (2009). Neural networks and statistical techniques: A review of applications. *Expert Systems with Applications*, 36(1), 2-17.
- Razykov, T., Ferekides, C., Morel, D., Stefanakos, E., Ullal, H., & Upadhyaya, H. (2011). Solar photovoltaic electricity: Current status and future prospects. *Solar Energy*, 85(8), 1580-1608.
- Roth, S., Hirschberg, S., Bauer, C., Burgherr, P., Dones, R., Heck, T., & Schenler, W. (2009). Sustainability of electricity supply technology portfolio. *Annals of nuclear energy*, 36(3), 409-416.
- Sovacool, B. K. (2010). Exploring the hypothetical limits to nuclear and renewable electricity future. *International Journal of Energy Research*, 34(13), 1183-1194.
- Tina, G., & Gagliano, S. (2010). Probabilistic analysis of weather data for a hybrid solar/wind energy system. *International Journal of Energy Research*.
- Wan Nik, W., Ibrahim, M., Samo, K., & Muzathik, A. (2012). Monthly mean hourly global solar radiation estimation . *Solar Energy*, 86(1), 379-387.
- Xu, F.-L., Zhao, S.-S., Dawson, R. W., Hao, J.-Y., Zhang, Y., & Tao, S. (2006). A triangle model for evaluating the sustainability status and trends of economic sustainability. *Ecological Modelling*, 195(3-4), 327-337.

