

## COMPARATIVO DE LA ESTIMACIÓN DE LA DEMANDA FUTURA DE FRIJOL EN MÉXICO MEDIANTE REGRESIONES LINEALES MÚLTIPLES Y REDES NEURONALES

**Chávez-Hurtado, José Luis**

Departamento de Métodos Cuantitativos  
CUCEA, Universidad de Guadalajara  
martedead@gmail.com

**Cortés-Fregoso, José Héctor**

Departamento de Métodos Cuantitativos  
CUCEA, Universidad de Guadalajara  
cortesfregoso@hotmail.com

### RESUMEN

En el presente trabajo se realiza un estudio comparativo entre una metodología empleando regresiones lineales múltiples y otra empleando redes neuronales para la estimación futura de la demanda de frijol en México. En ambos modelos se utilizaron bases de datos lineales, cuadráticas y logarítmicas para observar si alguna de las transformaciones en la base de datos origina un mejor pronóstico. Los resultados obtenidos muestran que el modelo basado en redes neuronales empleando la base de datos lineal es la que tiene un mejor desempeño en la estimación futura de la demanda de frijol teniendo un error absoluto promedio de 9.15%. El modelo más cercano fue la regresión lineal múltiple con una base de datos lineal la cual tuvo un error absoluto promedio de 18.17%. Este resultado coloca a las redes neuronales como una metodología viable para la estimación más precisa de la demanda futura de bienes.

**PALABRAS CLAVE. Redes Neuronales, Regresión Lineal Múltiple, Demanda futura.**

**Área principal. Otras aplicaciones en IO, Metaheurísticas, Programación Matemática.**

### ABSTRACT

This work makes a comparative analysis to forecast the demand of beans in Mexico by using a methodology based on multiple linear regressions and a methodology based on neural networks. Both models were built using a lineal, quadratic and logarithmic database in order to find if the lineal forecast performance can be improved. Results achieved show that the model based on neural networks and using the lineal database has the best performance with an absolute mean error of 9.15%. The closest model was the multiple linear regression based on lineal database with an absolute mean error of 18.17%. This result shows that neural network models can be used as an alternative to forecast goods demand with a better forecasting performance.

**KEYWORDS. Neural Networks. Multiple Linear Regression. Demand Forecasting.**

**Main area. Other applications in OR, Metaheuristics, Mathematical Programming.**

## 1. Introducción

Estimar la demanda futura de bienes dentro de un país es de suma importancia dadas las repercusiones sociales que puede tener una mala estimación de la demanda. El tener un exceso en la producción de un bien conlleva a tener una oferta mayor a la demanda y con ello una caída en los precios de los bienes. Esto trae como resultado una pérdida económica para los productores. Por otra parte podemos tener el caso en que la estimación de la demanda sea insuficiente y genere la escasez de bienes. En este caso tenemos una demanda mayor a la oferta de mercado lo que pone a los productores en posición de elevar los precios del producto ocasionando una pérdida económica de los consumidores. En ambos casos existe un actor económico que sale perjudicado, ya sea el productor o el consumidor. Sin embargo, si la estimación de la demanda fuera lo más certera posible podemos generar un escenario donde la oferta y la demanda de mercado son las óptimas, llegando al equilibrio de mercado donde tanto oferentes como consumidores alcanzan el beneficio máximo.

De acuerdo a la teoría económica, la demanda de un bien depende de diversos factores como el precio del bien, el precio de los bienes sustitutos y complementarios, las preferencias de los consumidores y el presupuesto de las personas (Nicholson, 2011). Existen diversas metodologías para la estimación de la demanda de un bien, el método más comúnmente empleado es el de regresión lineal múltiple en el que se busca encontrar la relación entre la demanda del bien y los demás componentes señalados por la teoría económica. Sin embargo no siempre la relación entre las variables independientes y la dependiente siguen una función lineal y es en estas ocasiones donde, de acuerdo a Binner et al. (2005), los modelos lineales alcanzan sus limitaciones y debemos emplear modelos no lineales como los basados en redes neuronales.

Las redes neuronales conforman una metodología que comienza a abrirse campo en el estudio de la demanda futura, sin embargo, los trabajos realizados en esta área se enfocan mayormente en la demanda de energía eléctrica (ej. Carmona et al. (2002); Yang y Yuanzhang (2008); Zhang et al. (2009)) o en la demanda de agua (ej. Chang y Liu (2009); Zhou y Yang (2010)), sin embargo, para esta investigación, no se encontraron trabajos relacionados con la estimación de la demanda de bienes agrícolas mediante redes neuronales. Por lo tanto el procedimiento empleado será similar a los trabajos de energía eléctrica o demanda de agua en donde iterativamente se busca el número de neuronas de la red que muestra el mejor desempeño en el pronóstico.

En la siguiente sección se presentará la metodología seguida para implementar tanto el modelo de regresión lineal múltiple como el modelo de red neuronal. En la sección 3 se compararán los resultados obtenidos por ambos modelos para finalmente emitir algunas conclusiones propiciadas por el presente trabajo de investigación.

## 2. Modelo de regresión lineal múltiple

### 2.1 Base de datos

Para la implementación del modelo de regresión lineal se creó una base de datos tomando como referencia la teoría económica. Por ello se utilizó como bienes sustitutos y complementarios del frijol al arroz, la cebolla, el chile, el jitomate, la lenteja, el maíz, la papa, la carne de cerdo, la carne de res y los huevos (todas las variables en pesos por tonelada). Estos datos fueron obtenidos de la página electrónica de FAOSTAT y conforman el período de 1991 al 2009 (datos más recientes al 15 de Marzo del 2012). Adicionalmente se incluyeron las variables de gasto familiar y población obtenidos de la base de datos del Banco Mundial y la demanda (en miles de toneladas) y precio del frijol (pesos por tonelada) obtenida también de FAOSTAT.

La base de datos resultante fue deflactada empleando la ecuación 1 para poder tener una referencia de comparación para todas las variables económicas. Una vez deflactada la base de datos se crearon dos nuevas bases: una base de datos cuadrática

(empleando la ecuación 2) y una base de datos logarítmica (empleando la ecuación 3).

$$P_{deflactado} = \left( \frac{I_{base}}{I_x} \right) (P_x) \quad \text{Ec. 1}$$

Donde:  $P_{deflactado}$  = Precio deflactado.  
 $I_{base}$  = Inflación acumulada correspondiente al año tomado como base.  
 $P_x$  = Precio del bien correspondiente al período a deflactar.  
 $I_x$  = Inflación acumulada correspondiente al período a deflactar.

$$V_{cuadrática} = (V_{lineal})^2 \quad \text{Ec. 2}$$

Donde:  $V_{cuadrática}$  = Variable de la base de datos cuadrática.  
 $V_{lineal}$  = Variable de la base de datos deflactada original.

$$V_{logarítmica} = \ln(V_{lineal}) \quad \text{Ec. 3}$$

Donde:  $V_{logarítmica}$  = Variable de la base de datos logarítmica.  
 $V_{lineal}$  = Variable de la base de datos deflactada original.

## 2.2 Estimación y validación de los modelos

Para la obtención del modelo de regresión lineal múltiple se emplearon las bases de datos descritas anteriormente y el programa E-Views. Una vez obtenido el modelo de regresión con las variables que conforman la base de datos se procedió a validar el modelo resultante. El proceso de validación consiste en ir eliminando una a una las variables cuyo valor estadístico no sea significativo al 95% de confianza, comenzando con la variable con el valor más cercano a cero en su estadístico t y terminando cuando todas las variables sean significativas.

Este proceso de validación se realizó con las tres bases de datos. En la tabla 1 se muestran los coeficientes del modelo resultante obtenido antes y después de la validación de variables.

Variable	Modelo lineal		Modelo cuadrático		Modelo logarítmico	
	Sin validar	Validado	Sin validar	Validado	Sin validar	Validado
C	-8.72E+06	x	-4.64E+06	-6.01E+06	-1.68E+08	-2.48E+08
DEMANDA_ANTERIOR	-6.87E-01	-6.12E-01	-3.10E-07	-2.85E-07	-4.53E+05	-4.76E+06
GASTO_FAMILIAR	-3.34E-07	x	-3.40E-20	-4.61E-20	-3.10E+06	1.81E+07
POBLACION	8.61E-02	x	5.68E-10	7.29E-10	1.21E+07	-4.38E+06
PRECIO_ARROZ	-2.34E+02	x	3.05E-02	x	-2.69E+06	4.66E+05
PRECIO_CEBOLLAS	2.44E+02	2.58E+02	3.91E-02	3.15E-02	5.39E+05	2.15E+06
PRECIO_CERDO	8.72E+01	1.17E+02	1.41E-03	6.23E-04	2.03E+06	-2.26E+05
PRECIO_CHILE	-2.13E+01	-1.52E+01	-3.07E-04	-2.52E-04	-2.90E+05	x
PRECIO_FRIJOLES	-2.09E+02	-1.93E+02	-2.02E-02	-1.88E-02	-5.65E+05	x
PRECIO_HUEVOS	1.06E+02	x	3.71E-03	4.92E-03	1.32E+06	1.19E+06
PRECIO_JITOMATE	-3.15E+01	x	-3.47E-03	x	-1.83E+04	x
PRECIO_LENTEJAS	-3.08E+01	x	-1.13E-03	x	-2.12E+05	x
PRECIO_MAIZ	7.58E+02	5.20E+02	1.63E-01	1.40E-01	1.89E+06	2.50E+06

PRECIO_PAPAS	4.04E+02	3.17E+02	2.81E-02	2.42E-02	3.03E+06	4.04E+06
PRECIO_VACUNO	-5.44E+01	-1.10E+02	-8.37E-04	x	-3.80E+05	x

Tabla1. Coeficientes resultantes para el modelo de regresión lineal múltiple con la base de datos lineal, cuadrática y logarítmica; antes y después de validar el modelo.

### 3. Modelo de redes neuronales

De acuerdo con Haykin (1999) una red neuronal es un procesador masivo en paralelo compuesto de unidades de procesamiento simple denominadas neuronas, las cuales tienen una propensión natural a almacenar conocimiento y volver disponible para su uso. La unidad de procesamiento básico (neurona) se compone de tres partes:

1. La sinapsis o enlaces, las cuales tienen al menos un peso ( $w$ ) asignado que se multiplica por la señal a la entrada del enlace.
2. Un sumador, el cual suma las señales ponderadas de la entrada con una señal de alimentación ( $b$ ).
3. Una función de activación no lineal ( $\varphi$ ), la cual define el comportamiento del modelo de red neuronal.

La estructura general de una neurona se muestra en la figura 1, mientras que la ecuación correspondiente para el valor de salida ( $y$ ) se muestra en la ecuación 4.




Figura1. Estructura general de una neurona. Cada entrada es multiplicada por un peso  $W$  y el valor resultante se suma con una señal de alimentación  $b$ . Al resultado de dicha suma se aplica una función de activación no lineal  $\varphi$  para obtener el valor de salida resultante.

$$y = \varphi(w_{kj}x_j + b_k) \tag{Ec. 4}$$

Una red neuronal se asemeja al funcionamiento del cerebro en que adquiere su conocimiento mediante un proceso de aprendizaje de su entorno y en que los pesos sinápticos son empleados para guardar el conocimiento adquirido. De acuerdo con Pérez y Martín (2005) se pueden distinguir dos fases en la operación de la red neuronal:

1. Una fase de aprendizaje, en donde la red neural aprende a resolver el problema deseado mediante un proceso de modificación de los pesos sinápticos.
2. Una fase de memoria, durante la cual los pesos sinápticos permanecen constantes y en donde la red neuronal puede ser empleada para determinar un valor de salida ante un nuevo valor de entrada.

Una red neuronal se divide al menos en tres capas: una capa de entrada, una capa de salida y una capa intermedia, denominada capa oculta. Cada una de las capas se componen de al menos una neurona. Según García et al. (2003) y Binner et al. (2005) una red neuronal con una o dos capas ocultas es suficiente para aproximar una función de cualquier orden, siempre y cuando se cuente con la cantidad de información necesaria.

Dada la falta de trabajos e información sobre el uso de redes neuronales para la estimación de la demanda, no existe una metodología para determinar de manera precisa el

número de capas ocultas y de neuronas que deben emplearse. Por esta razón utilizaremos la metodología empleada trabajos como los de Nakamura (2005), Binner et al. (2005) y Choudhary y Haider (2008) en donde se va incrementando de manera iterativa el número de neuronas en el modelo hasta que se obtiene el desempeño deseado.

### 3.1 Metodología

Para comenzar la selección del modelo de red neuronal se empleó la base de datos previamente utilizada para estimar los modelos de regresión lineal múltiple. Por lo tanto se obtendrá un modelo de red neuronal para la base lineal, otro para la base cuadrática y uno más para la base logarítmica, de tal forma que podamos hacer una comparación entre cada uno de los modelos y determinar si alguno de ellos ayuda a mejorar el desempeño de la red neuronal.

El proceso de selección del modelo de red neuronal comienza estableciendo las condiciones iniciales del modelo: el número inicial de capas ocultas y de neuronas, el tipo de función de activación deseada, el porcentaje de datos que se empleará para la fase de aprendizaje y para la fase de memoria, y de manera automática el programa asigna valores iniciales a los pesos sinápticos de la red neuronal. Para este trabajo especificamos una red neuronal con 1 capa oculta que puede contener de 1 a 50 neuronas.

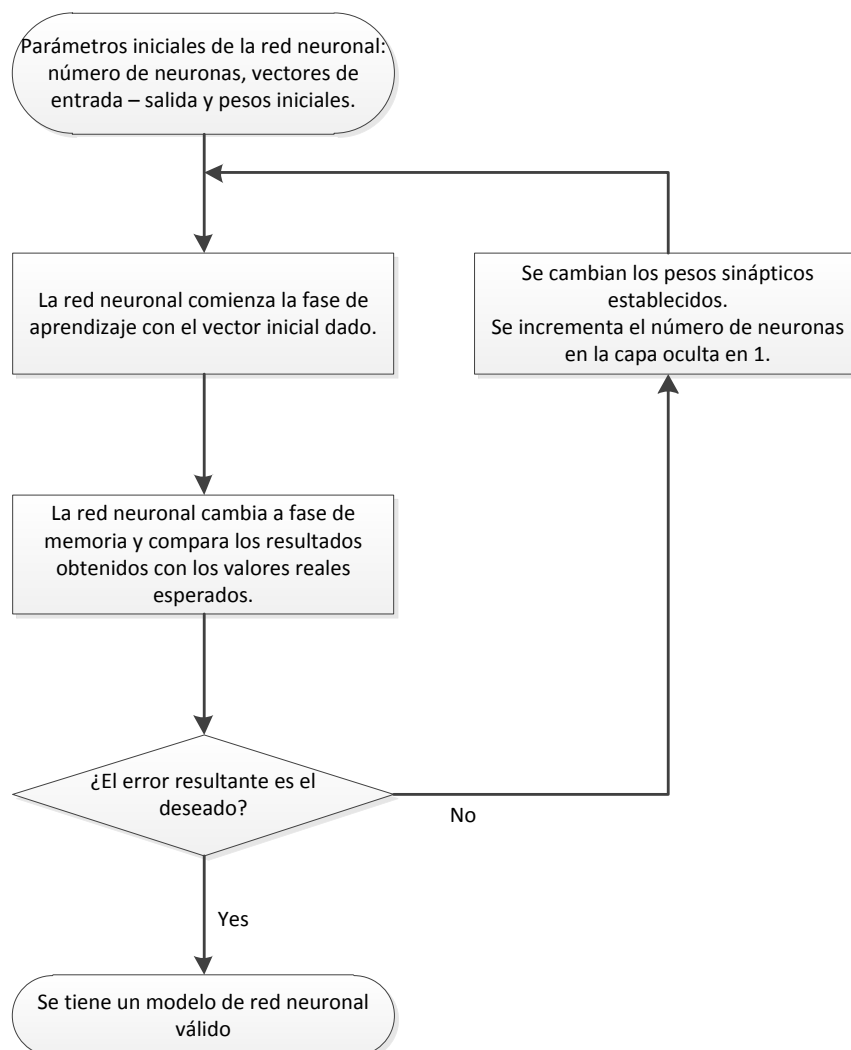


Figura2. Diagrama de flujo empleado para la selección del mejor modelo de red neuronal para cada una de las bases de datos empleada.

Para seleccionar el número adecuado de neuronas se realizó un proceso iterativo en el que se simulaba 10 veces la red neuronal comenzando con 1 neurona en la capa oculta. Al cabo de 10 simulaciones, si el error resultante no era el esperado, el número de neuronas en la capa oculta se aumentaba en 1 unidad. De esta forma se realizó el proceso hasta encontrar el modelo de red neuronal que mejor se ajustará a los datos de entrada – salida.

Se estableció que el modelo resultante debía tener un error menor al 10% del valor promedio de la demanda de frijol en México, por ello se estableció un error medio de  $1E+8$ . De esta forma, si un modelo de red neuronal tenía en su fase de entrenamiento un error menor a dicha cantidad, el modelo era aceptado para realizar la estimación futura de la demanda. El diagrama de flujo de la metodología para selección del modelo de red neuronal se muestra en la figura 2.

#### 4. Resultados

##### 4.1 Regresión lineal múltiple

Se utilizó la base de datos de 1991 al 2007 para generar el modelo de regresión lineal múltiple, y los valores del 2008 al 2009 para determinar la precisión del modelo en la estimación de la demanda futura.

Para el modelo de regresión lineal múltiple empleando la base de datos lineal se generaron dos modelos, uno con las variables sin validar y otro con las variables validadas al 95%. El modelo sin validar tiene un error absoluto medio de 3.28% en el período de 1991 al 2007, mientras que el modelo validado tiene un error absoluto medio de 7.33%. En la figura 3 se puede observar la curva de demanda real y la curva generada por ambos modelos.




Figura 3. Curva de demanda resultante para los modelos de regresión lineal múltiple empleando la base de datos lineal sin validar y validada, para el período de 1991 al 2007. El modelo sin validar tuvo un error absoluto medio de 3.28% mientras que para el validado fue de 7.33%.

De la misma manera para la base de datos cuadrática se generaron dos modelos de regresión lineal múltiple, uno de ellos con las variables sin validar y el otro con las variables validadas al 95%. El primer modelo tuvo un error absoluto medio de 3.33%, mientras que el segundo tuvo un error absoluto medio de 4.69%. La figura 4 muestra el comportamiento de ambos modelos para el período 1991 – 2007.




Figura 4. Curva de demanda resultante para los modelos de regresión lineal múltiple empleando la base de datos cuadrática sin validar y validada, para el período de 1991 al 2007. El error absoluto medio para el modelo sin validar fue de 3.33% mientras que para el modelo validado fue de 4.69%.

Finalmente, para la tercera base de datos se realizó el mismo procedimiento donde se generaron dos modelos de regresión lineal. El modelo sin validar tuvo error absoluto medio de 9.65% mientras que el modelo validado tuvo un error de 8.56%. En la figura 5 se puede observar el comportamiento de dichos modelos en el periodo 1991-2007.




Figura 5. Curva de demanda resultante para los modelos de regresión lineal múltiple empleando la base de datos logarítmica sin validar y validada, para el período de 1991 al 2007. El error absoluto medio para el modelo sin validar fue de 9.65% mientras que para el modelo validado fue de 8.56%.

#### 4.2 Redes neuronales

Para los modelos basados en redes neuronales se siguió el mismo procedimiento, por tanto, se generaron dos modelos empleando la base de datos lineal: uno donde se incluían todas las variables de la base de datos y otro donde sólo se incluían las variables validadas mediante el modelo de regresión lineal múltiple. Empleando la metodología de selección de neuronas, el primer modelo resultó en una red neuronal con 1 capa oculta y 37 neuronas en su interior (Figura 6a), mientras que el segundo modelo también consta de 1 capa oculta pero con 11 neuronas en su interior (Figura 6b). El error absoluto medio para el modelo con las variables sin validar fue de 5.88%, mientras que para el modelo con las variables validadas fue de 9.33%. El comportamiento de ambos modelos puede observarse en la figura 7.




Figura 6. Modelo de red neuronal resultante empleando la base de datos lineal sin validar (6a) y la base de datos lineal validada (6b). Ambos modelos constan de 1 capa de entrada, 1 capa de salida y 1 capa oculta intermedia.




Figura 7. Curva de demanda resultante para los modelos de red neuronal empleando la base de datos lineal sin validar y validada, para el período de 1991 al 2007. El error absoluto medio para el modelo sin validar fue de 5.88% mientras que para el modelo validado fue de 9.33%.

Empleando la base de datos cuadrática se obtuvo un modelo con 1 capa oculta y 48 neuronas empleando las variables sin validar (Figura 8a), mientras que empleando las variables validadas por el modelo de regresión lineal se obtuvo una red neuronal con 1 capa oculta y 4 neuronas en su interior (Figura 8b). El error absoluto medio del primer modelo fue de 5.65% mientras que para el segundo modelo fue de 0.53%. La curva resultante de ambos modelos para el período 1991-2007 se puede observar en la figura 9.



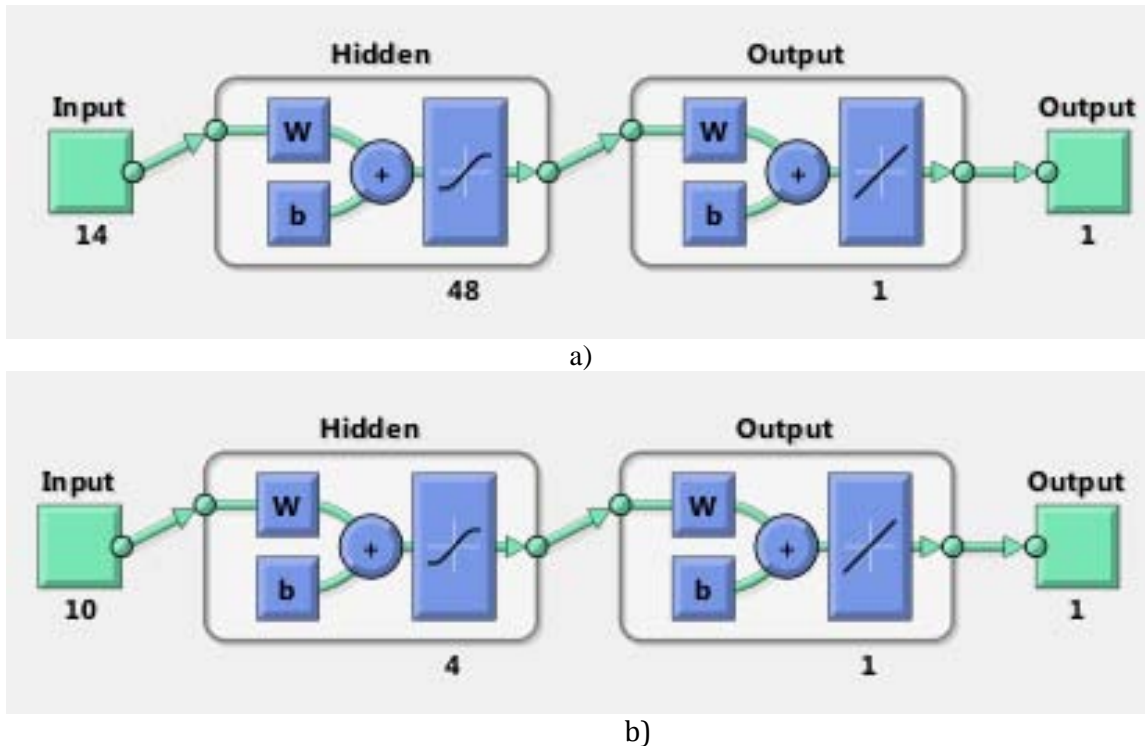


Figura 8. Modelo de red neuronal resultante empleando la base de datos cuadrática sin validar (8a) y la base de datos cuadrática validada (8b). Ambos modelos constan de 1 capa de entrada, 1 capa de salida y 1 capa oculta intermedia.




Figura 9. Curva de demanda resultante para los modelos de red neuronal empleando la base de datos cuadrática sin validar y validada, para el período de 1991 al 2007. El error absoluto medio del modelo sin validar fue de 5.65% mientras que para el segundo modelo fue de 0.53%.

Finalmente, de igual forma para la base de datos logarítmica se establecieron dos modelos. El modelo resultante empleando la base de datos sin validar consta de 1 capa oculta con 36 neuronas (Figura 10a), mientras que el modelo resultante empleando la base de datos validada consta de 1 capa oculta con 3 neuronas (Figura 10b). Para el primer modelo el error absoluto medio fue de 0.37% mientras que para el segundo modelo fue de 3.00%. El comportamiento de los modelos en el período 1991-2007 se muestra en la figura 11.




Figura 10. Modelo de red neuronal resultante empleando la base de datos logarítmica sin validar (10a) y la base de datos logarítmica validada 10b). Ambos modelos constan de 1 capa de entrada, 1 capa de salida y 1 capa oculta intermedia.




Figura 11. Curva de demanda resultante para los modelos de red neuronal empleando la base de datos logarítmica sin validar y validada, para el período de 1991 al 2007. El error absoluto medio del modelo sin validar fue de 0.37% mientras que para el modelo validado fue de 3.00%.

#### 4.3 Estimación de la demanda futura

Utilizando como variables de entrada los datos correspondientes a los años 2008 y 2009 se estimó la demanda futura empleando cada uno de los 12 modelos generados (6 correspondientes a regresión lineal múltiple y 6 correspondientes a redes neuronales). Los resultados obtenidos muestran que la red neuronal obtenida de la base de datos lineal validada es el que muestra un mejor desempeño en el pronóstico de la demanda con un error medio absoluto de 9.5%. El segundo mejor modelo fue el obtenido mediante la regresión lineal múltiple empleando también la base de datos lineal validada. Su error absoluto medio fue de 18.17%, casi el doble que el obtenido con la red neuronal. La tabla 2 muestra el resultado obtenido por los modelos en la estimación de la demanda futura

ordenados de acuerdo al error absoluto medio resultante.

	AÑO	2008	2009	E.A.M. 2008-2009	E.A.M. 1991-2007
	DEMANDA REAL	1,122,720.00	1,041,350.00	-	
1	R.N. LINEAL VALIDADA	1,305,534.59	1,020,255.71	9.15%	9.33%
2	R.L.M. LINEAL VALIDADA	1,229,086.40	1,321,204.31	18.17%	7.33%
3	R.N. CUADRATICA SIN VALIDAR	1,079,507.63	578,113.59	24.17%	5.65%
4	R.L.M. CUADRATICA VALIDADA	1,381,224.07	1,337,372.70	25.73%	4.69%
5	R.N. CUADRATICA VALIDADA	741,690.71	754,271.26	30.75%	0.53%
6	R.L.M. LINEAL SIN VALIDAR	1,205,445.72	1,658,947.07	33.34%	3.28%
7	R.N. LINEAL SIN VALIDAR	1,800,951.98	1,257,069.43	40.56%	5.88%
8	R.L.M. CUADRATICA SIN VALIDAR	1,680,813.68	1,406,958.88	42.41%	3.33%
9	R.N. LOGARITMICA SIN VALIDAR	1,488,194.06	1,639,355.07	44.99%	0.37%
10	R.N. LOGARITMICA VALIDADA	403,015.55	465,773.29	59.69%	3.00%
11	R.L.M. LOGARITMICA SIN VALIDAR	374,647.96	1,761,732.06	67.90%	9.65%
12	R.L.M. LOGARITMICA VALIDADA	527,930.31	1,863,458.56	112.98%	8.56%

Tabla2. Resultados obtenidos para la estimación de demanda futura correspondiente al período 2008-2009. El modelo de red neuronal estimado a partir de la base de datos lineal validada fue el que mostró el mejor desempeño con un error absoluto medio (E.A.M.) de 9.15%.

## 5. Conclusiones

En el presente trabajo se hizo un comparativo para la estimación de demanda futura entre modelos basados en regresiones lineales múltiples y modelos basados en redes neuronales artificiales. Los resultados arrojan que la red neuronal artificial generada a partir de la base de datos lineal validada fue la que obtuvo un mejor desempeño en la estimación de la demanda futura con un error absoluto medio de 9.15%.

De los resultados obtenidos podemos observar que no existe una relación directa entre el error absoluto medio de los modelos obtenidos en la etapa de generación del modelo (1991-2007) y el error absoluto medio resultante en la estimación de la demanda futura.

Respecto a la generación de los modelos de redes neuronales se puede observar

que aquellos que utilizan la base de datos validada emplean un menor número de neuronas en la capa oculta. Esto puede ser una ventaja para reducir el tiempo y costo de simulación del modelo. Sin embargo, el emplear una base de datos con variables validadas no garantiza obtener un pronóstico con un menor error absoluto medio. En este trabajo las variables fueron determinadas estadísticamente a través de las regresiones lineales múltiples, puede emplearse otro tipo de metodologías para determinar las variables válidas del modelo y tratar de mejorar el desempeño del modelo.

## Referencias

- Binner, J., Bissoondeal, R., & Elger, T. (2005). A comparison of linear forecasting models and neural networks: an application to Euro inflation and Euro Divisia. *Applied Economics*, 37(6), 665-680.
- Carmona, D., Jaramillo, M., Gonzalez, E., & Alvarez, J. (2002). Electric energy demand forecasting with neural networks. *IECON 02*, 1860-1865.
- Chang, M., & Liu, J. (2009). Water Demand Prediction Model Based on Radial Basis Function Neural Network. *Information Science and Engineering*, 5295-5298.
- Choudhary, A., & Haider, A. (2008). *Neural Network Models for Inflation Forecasting: An Appraisal*. Retrieved Septiembre 15, 2010, from Department of Economics Discussion Papers, University of Surrey: <http://econpapers.repec.org/paper/sursurrec/0808.htm>
- García, M., Bello, R., Diaz, A., & Reynoso, A. (2003). *Redes neuronales artificiales*. Guadalajara, Mexico: Universidad de Guadalajara.
- Haykin, S. (1999). *Neural Networks* (2nd ed.). United States: Prentice Hall.
- Nakamura, E. (2005). Inflation Forecasting using a Neural Network. *Economics Letters*, 86, 373-378.
- Nicholson, W., & Snyder, C. (2011). *Microeconomía intermedia y su aplicación*. CENGAGE Learning.
- Pérez, M. L., & Martín, Q. (2003). *Aplicaciones de las redes neuronales artificiales a la estadística*. Madrid, España: La Muralla.
- Yang, B., & Yuanzhang, S. (2008). An improved neural network prediction model for load demand in day-ahead electricity market. *Intelligent Control and Automation*, 4425-4429.
- Zhang, W., Wang, Y., Wang, J., & Liang, J. (2009). Electricity Demand Forecasting Based on Feedforward Neural Network Training by a Novel Hybrid Evolutionary Algorithm. *Computer Engineering and Technology*, 98-102.
- Zhou, J., & Yang, K. (2010). General regression neural network forecasting model based on PSO algorithm in water demand. *Knowledge Acquisition and Modeling*, 51-54.