

# ***Predicción de Consumo de Energía Basada en Sistemas Conexionistas”***

(<sup>1</sup>) J. Martinez, (<sup>2</sup>) C. Navarro, (<sup>3</sup>) J. Ierache

**Facultad de Informática Ciencia de la Comunicación y Técnicas Especiales**  
**(<sup>4</sup>) Instituto de Sistemas Inteligentes y Enseñanza Experimental de la Robótica (ISIER)**  
**Universidad de Morón Cabildo 134, (B1708JPD) Morón, Buenos Aires, Argentina**  
**54-11-56272000 interno 189/746 , 54-11-56274520**

jamartinez@unimoron.edu.ar (1), cnavarro@unimoron.edu.ar, (2), jierache@unimoron.edu.ar(3)  
isier@unimoron.edu.ar(<sup>4</sup>)

## **Resumen**

*El presente trabajo describe los resultados generales de la investigación realizada para la predicción de la demanda energética en la República Argentina desde un caso de estudio particular. Dicho caso permite abordar cuestiones particulares, como la penalización correspondiente a la fuente de energía particular. Se ha elegido como caso de estudio la demanda de gas natural debido a que ésta ofrece la mayor complejidad respecto a las otras fuentes. Con el fin de resolver el problema de la predicción de la demanda se construye un ensamblado de redes neuronales previamente obtenidas y evaluadas.*

## **1. Introducción**

La problemática de la predicción de energía ha sido abordada con diferentes tecnologías. Las metodologías clásicas no han aportado una solución acorde a las demandas de los respectivos entes reguladores. Esto ha llevado a las empresas involucradas en este servicio a buscar otros métodos con el fin de realizar una predicción del consumo energético con mayor exactitud.

En este caso de estudio se ha planteado un modelo para la predicción de la demanda de gas natural de nuestro país, basado en un ensamblado de redes neuronales que permite la mejora en el desempeño individual de las mismas. Para conseguir dicho ensamblado se realizó la simulación de distintas topologías de redes neuronales de propagación hacia adelante, como las MLP (Perceptron Multicapa) y las RBF (Redes Neuronales con funciones de base radial), recurriendo al uso de una herramienta destinada a tal fin, el Statistica Neural Networks. Otra estructura utilizada en dicho ensamblado es una red de Elman, aportando al modelo un estado interno que contribuye con un comportamiento dependiente de estados anteriores. Para conseguir esta red se construyó un prototipo de simulador implementando el clásico algoritmo de retropropagación del error, o backpropagation, con la adición del término momento.

## **2. Caso de estudio representativo**

Con el objetivo de abordar un caso de estudio sobre la predicción de la demanda energética se procede con la exposición del caso para el gas natural. La zona donde se realiza la predicción es acotada a la extensión geográfica de la provincia de Buenos Aires, república Argentina, debido a que ésta es el área de mayor consumo de energía y a su vez de mayor densidad poblacional.

El objetivo del caso de estudio es la pronosticación de la demanda del día siguiente, ya que solo esta situación es pasible de penalización. Este se ajusta a la demanda de las fuentes de energía de mayor actividad en la población en cuestión.

Las empresas distribuidoras se encargan de disminuir las presiones de operación utilizando estaciones de regulación para cumplir con las pautas dictadas por la norma denominada “*Normas mínimas de seguridad para el transporte y distribución de gas natural y otros gases por cañerías*” [Enargas 1993].

La etapa final es la medición del consumo de cada cliente mediante un medidor con un error conocido, de un caudal máximo, que registra los m<sup>3</sup> acumulados [Enargas 1992]. Debido a que la medición para cada usuario se realiza mensual o bimestralmente, resulta imposible conocer el comportamiento de la demanda de cada usuario en cada día. Para abordar este inconveniente se emplean sistemas SCADA, Control supervisor y adquisición de datos, que obtienen mediciones de los puntos de transferencia, entrega desde los transportistas y traspaso a otras distribuidoras.

La normativa obliga a las distribuidoras a comunicar formalmente antes de las 12 horas de cada día los volúmenes que estima requerirán al corto plazo, entendiéndose por esto los 4 días subsiguientes [Ley 24076]. De esta forma, los despachos de los productores y transportistas pueden planificar eficientemente la operación del sistema con antelación suficiente.

Con el objetivo de conocer los factores más relevantes para la demanda de gas natural se han evaluado los trabajos [Gil 2002], [Arrufat 1993] y [Box 1970]. [Gil 2002] introduce el concepto de temperatura efectiva; En [Arrufat 1993] los autores plantean la existencia de 2 temperaturas de referencia que gobiernan el comportamiento de los usuarios, los 18 y 10 grados Celsius y [Box 1970] desarrollaron una metodología llamada ARIMA, Autorregresive Integrated Moving.

Se ha considerado también que debilidad de los modelos lineales es la incapacidad de representar series temporales reales que posean comportamientos no lineales, para los cuales, en muchos casos no existen suficientes leyes físicas o económicas que permitan especificar completamente un modelo estadístico para su representación, véase [Granger 1993].

Otros trabajos valorados fueron [Doumanian 2000], [Paggi 2007] [Paggi 2007] y [AGA 1992]. [Doumanian 2000] incluye el modelo de autoregresión generalizada ARIMA combinado con redes neuronales. La empresa norteamericana William Gas Pipeline implementó con éxito un sistema basado en Perceptron multicapa para el pronóstico de la demanda a corto plazo [Lam 1998]. [Paggi 2007] utiliza modelos ARIMA y diversas configuraciones de redes neuronales para la predicción del consumo de gas en garrafas. Por último la organización American Gas Association (A.G.A.) recomienda el uso de diversas técnicas de regresión para el pronóstico de consumo en su Práctica de Series de Operación [AGA 1992].

Los factores influyentes en la demanda de gas natural educidos del análisis de los trabajos citados y utilizados para los modelos evaluados en el presente artículo son climáticos, de tipo calendario, macroeconómicos y distintas representaciones de la demanda previa. De estos factores se extraen las variables analizadas que se contemplan en el desarrollo de un ensamblado de redes neuronales, ver [Bishop 2000].

### **3. Propuesta**

Las soluciones existentes detalladas en el apartado anterior, en general miden la bondad de las predicciones con el error medio cuadrático y no garantizan una minimización de los casos de predicción fuera de la banda de tolerancia. La normativa vigente no es flexible referente a los errores aceptables en las nominaciones de gas natural y establece un conjunto de penalidades que varía en función del estado de los sistemas de transporte para errores entre un 5% y un 15% [Enargas 1992, 1995]. Con el objetivo de encontrar una solución, se exploraron exhaustivamente todas las arquitecturas de redes neuronales soportadas por la aplicación Statistica Neural Networks. Para incluir en un ensamblado las redes neuronales recurrentes de tiempo discreto, TDNN, se construyó un prototipo con redes de Elman [Elman 1990]. Para concretar la propuesta se plantea la

solución representada en el esquema de la Figura 3-1 donde se observa la base de datos, los procesos de exploración y evaluación, los modelos generados y la aplicación de ensamblado. La base de datos se conforma de la información obtenida del ENARGAS, INDEC, Servicio Meteorológico Nacional y los datos calendarios. La misma aporta los datos normalizados y no normalizados necesarios para efectuar la exploración de redes neuronales con SNN y la herramienta de exploración de redes de Elman. Luego de dichas exploraciones de las aptitudes de cada modelo, se realiza una evaluación que arroja resúmenes y modelos que permiten la construcción de la aplicación ensamblado.

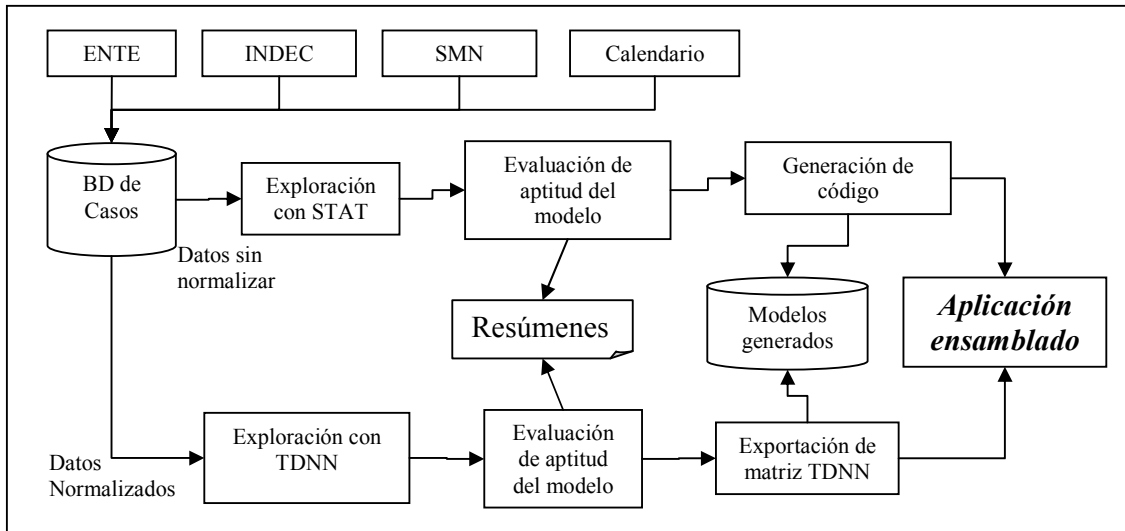


Figura 3-1. Esquema del modelo de predicción de demanda de energía propuesto

#### 4. Resultados

Finalizados los cálculos para todos los modelos con todos los casos del conjunto de predicción, se sintetizan los resultados obtenidos con el fin de evaluar el desempeño. El análisis riguroso de los resultados expuestos en este capítulo permite obtener conclusiones.

La solución propuesta con el ensamblado de tres redes MLP y una red de Elman obtuvo los valores de error relativo medio absoluto,  $E_{RMA}$ , mostrados en la Tabla 1. También se citan en la misma el porcentaje de los casos incluidos en las bandas de error relativo absolutos.

Tabla 1. Valores absolutos de los errores relativos del ensamblado.

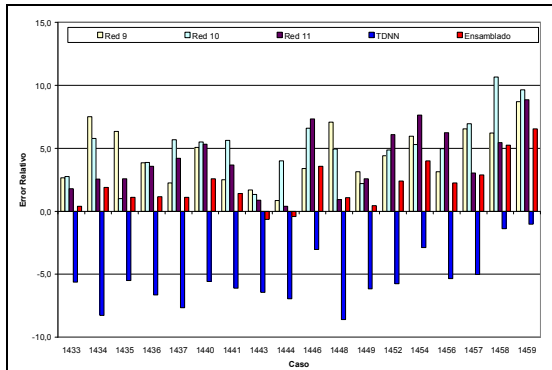
$E_{RMA}$	Porcentaje de Casos						
	0-5	0-7	0-10	0-15	0-20	0-30	0-100
0,034	78,2%	89,6%	95,5%	98,2%	99,6%	99,6%	100%

La Tabla 2 muestra un resumen de los resultados de los 220 casos reservados para predicción con todas las técnicas clásicas y conexionistas obtenidas. La presentación de la información contenida en la misma concuerda con la de tabla precedente. De los resultados finales obtenidos en los casos de predicción se destacan algunos casos singulares que merecen un estudio puntual. En los 18 casos del gráfico de barras de la Figura -1 se destaca la compensación aportada por la red de Elman (TDNN) debido a que posee un error relativo de signo negativo, mientras que los MLP son de signo positivo. Este efecto provoca que el error relativo del ensamblado sea significativamente menor.

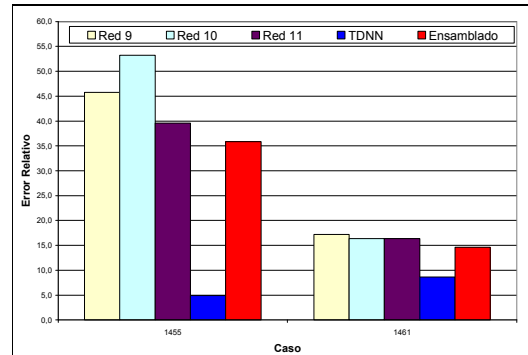
**Tabla 2. Resultados comparativos.**

Modelo	$E_{RMA}$	0-5	0-7	0-10	0-15	0-20	0-30	0-100
Regresión Simple (pol. 3 <sup>er</sup> orden)	0,148	20,9%	29,5%	45,9%	62,7%	76,2%	90,9%	100%
Regresión Generalizada	0,100	36,3%	46,9%	61,2%	76,7%	82,9%	90,5%	100%
MLP 9	0,041	70,0%	85,0%	94,6%	97,8%	98,7%	99,3%	100%
MLP 10	0,039	74,1%	88,7%	95,2%	95,2%	99,0%	99,6%	100%
MLP 11	0,038	74,5%	89,1%	95,6%	98,8%	99,3%	99,6%	100%
TDNN	0,052	52,0%	71,8%	91,8%	98,2%	99,5%	100%	100%
Ensamblado	0,034	78,2%	89,6%	95,5%	98,2%	99,6%	99,6%	100%

Otros casos de difícil pronosticación son los días festivos más populares en nuestro país, Navidad y fin de año. En la Figura -2 se muestran los errores relativos para estos días, destacándose el reducido error relativo obtenido por la TDNN.



**Figura -1. Compensación de error por empleo de red de Elman.**



**Figura -2. Errores relativos en Navidad y Fin de Año.**

## 5. Conclusiones y futuras líneas de investigación

En el caso de estudio detallado en la sección 2 se observa un conjunto de factores influyentes. De estos factores se concluye que las variables que aportan más información son la demanda previa, las variables de tipo calendario y el clima, siendo el clima la más relevante de éstas. En cuanto a la solución propuesta presentada en la sección anterior se concluye que los resultados obtenidos por las redes neuronales MLP y Elman encontradas superan ampliamente la cantidad de casos dentro de las mismas bandas de errores relativos que los logrados con los modelos matemáticos convencionales, regresión simple y regresión generalizada, tal como se muestra en la Tabla 2. A partir de los modelos obtenidos en el presente trabajo se destaca que la red neuronal denominada como red 11 en la ha obtenido un mejor desempeño a pesar de poseer una sola capa oculta con 6 neuronas. La red 9 logra resultados similares con dos capas ocultas conteniendo 60 y 15 neuronas y la red 10 también con 2 capas ocultas de 66 y 37 neuronas. De esto se concluye que el SNN ha

encontrado un mínimo en la función de error global de la red 11, que se acerca mucho más al global que en las otras redes. A partir de esto se observa la necesidad de implementar algoritmos que exploren ampliamente la superficie de error con el fin de encontrar mínimos que se acerquen al mínimo global. También puede observarse que el ensamblado obtenido con las redes antes nombradas arroja un error inferior al obtenido con las redes que lo conforman. Es notable que el ensamblado logre la mayor cantidad de casos en las bandas de error más exigentes, un 78,2% entre 0 y 5% y un 89,6% entre 0 y 7%. De esto se concluye que el ensamblado provee mayor exactitud en la predicción ya que consigue errores inferiores para los casos con menor error. Finalmente los casos particulares correspondientes a navidad y fin de año representados en la Figura -2 muestran la aptitud de la red de Elman para predecir situaciones anómalas. De esto se concluye que la predicción de la demanda puede mejorarse notablemente empleando un pre-procesamiento simbólico donde un conjunto de reglas seleccione el ensamblado o red adecuada para el caso particular. Las futuras líneas de investigación se orientan: [a] Sistema de preprocesamiento simbólico para seleccionar las redes neuronales del ensamblado para cada caso particular (cada día). [b] Integración de la predicción de demanda de otras fuentes de energía (principalmente energía eléctrica), [c] Sistema de planificación de cortes para el corto plazo, [d] Generación automática de esquemas de predicción basada en algoritmos evolutivos.

## 6. Referencias

- [AGA 1992] American Gas Association. *Gas Engineering Operating Practice Series*.
- [Arrufat 1993] Arrufat J. y Neder A. *Estimación de funciones de demanda de gas natural para consumo residencial en la Argentina*. Universidad de Córdoba.
- [Bishop 2000] Bishop C. M. *Neural Networks for Pattern Recognition*. Ed. Oxford University Press, 2000.
- [Box 1970] Box G. y Jenkins G. *Time Series Analysis: Forecasting and Control*, San Francisco.
- [Doumanian 2000] Doumanian J. y Sanfeliu J. M. *Sistema de predicción de la demanda de gas natural basado en la aplicación de inteligencia artificial y redes neuronales*. 2do. Congreso Latinoamericano y del Caribe de Gas y Electricidad. Año 2000.
- [Elman 1990] Elman, J. L. (1990). *Finding structure in time*, *Cognitive Science*, 14,179–211.
- [Enargas 1992] *Licencia de Distribución de Gas Natural*. Decreto 2255/92.
- [Enargas 1993] NAG 100. *Normas mínimas de seguridad para el transporte y distribución de gas natural y otros gases por cañerías*. Año 1993.
- [Enargas 1995] Resolución Enargas 716/1995. *Reglamentos Internos de los Centros de Despachos*
- [Gil 2000] Gil S., Deferrari J. *Análisis de Situaciones de Riesgo en el Abastecimiento de Gas Natural al Gran Buenos Aires*. 2do Congreso Latinoamericano y del Caribe de Gas y electricidad. Año 2000.
- [Gil 2002] Gil S., Deferrari J., Duperron L. *Modelo generalizado de predicción de consumos de gas natural a mediano y corto plazo*. 3er Congreso Latinoamericano y del Caribe de Gas y electricidad. Año 2002.
- [Gil 2004] Gil S., Deferrari J., Duperron L. *Modelo generalizado de predicción de consumos de gas natural a mediano y corto plazo*. 5to Congreso Latinoamericano y del Caribe de Gas y electricidad. Año 2004.
- [Granger 1993] Granger, C. y Teräsvirta, T. *Modeling Nonlinear Economic Relationships*.
- [Lam 1998] Lam, J. C. *Climatic and economic influences on residential electricity consumption*. *Energ. Convers. Manage.* 1998 , 39, 623–629.
- [Ley 24076] Marco Regulatorio de la Actividad. *Privatización de Gas del Estado Sociedad del Estado. Transición. Disposiciones Transitorias y Complementarias*. Disponible en internet en <http://www.ausp.org.ar/24076.htm>.
- [Paggi 2007] Paggi H. *Predicción De Series Temporales Usando Redes Neuronales. Un Caso De Estudio*. XXII Jornadas Anuales de Economía. Republica Oriental del Uruguay.