

La necesidad de optimizar los requerimientos energéticos de una empresa impulsan la aplicación de **métodos predictivos del consumo de combustible** mediante el uso de modelos inteligentes tales como las redes neuronales artificiales.



# Predicción del consumo de combustible para industrias mediante redes neuronales artificiales

## *Prediction of Fuel Consumption for Industry by Artificial Neural Networks*

### RESUMEN

El presente artículo expone una metodología utilizada para la predicción de consumo de combustible con el objetivo de realizar estrategias operativas para un abastecimiento continuo con reducción de riesgos y minimización de costos. Ello es posible si se efectúan simulaciones con los resultados predichos.

La predicción se lleva a cabo con la ayuda de Redes Neuronales Artificiales, basada en el histórico de los consumos en un periodo de dos o más años. Se aplicó la metodología en cinco industrias con diferentes productos y ciclos de producción y se obtuvieron resultados muy aceptables (error promedio inferior al 2%) si se considera que el consumo de cada industria está ligado a la demanda de su producto, mantenimientos programados y no programados, entre otros. Así, se demuestra que el uso de redes neuronales es eficiente en el reconocimiento de patrones de consumo de combustible, lo que permite su integración con otras metodologías para optimizar la logística.

### ABSTRACT

*This article presents a methodology for the prediction of fuel consumption aiming to design operational strategies for a continuous supply, reducing risks and minimizing costs. This is possible if simulations are performed with predicted data.*

*For prediction we used artificial neural networks, a methodology based on historical consumption in a period of two years or more. It was applied to five industries with different products and production cycles. The results were very acceptable considering that, in each case, fuel consumption is linked to the demand of products or scheduled or non-programmed maintenance. Therefore, it is demonstrated that neural*

*networks are efficient for identification of fuel consumption patterns allowing their integration with other methodologies in order to optimize logistics of industries.*

### INTRODUCCIÓN

La competitividad de una empresa está centrada en su capacidad de brindar un buen servicio al menor costo posible. Aunque esta premisa es muy simple y fácil de comprender encierra varios conceptos y metodologías complejas y muy elaboradas.

La competitividad es definida como la capacidad de generar la mayor satisfacción posible de los consumidores en base a un precio o de ofrecer un menor precio, fijado un estándar de calidad. Por lo tanto, las empresas más competitivas podrán asumir un rol más activo en el mercado al desplazar a las empresas menos competitivas, de no existir distorsiones del mercado que impidan dicho desenvolvimiento [3].

En la actualidad, las empresas buscan ser competitivas (mediante el mejoramiento de sus procesos, el empleo eficiente de sus recursos disponibles, la apuesta en tecnología, investigación e innovación) con inversión de capital humano y/o financiero. En un mundo dinámico y comercialmente agresivo es fundamental estar en un proceso de mejora continua, el cual puede hacer la diferencia entre una empresa que se desarrolla o desaparece. Un ejemplo reciente nos permite ver con mayor claridad este concepto.

A partir del año 2014 se observó, debido a diversos sucesos internacionales (la desaceleración económica de China, la depreciación de divisas frente al dólar, etc.), que las materias primas incluyendo el petróleo (Figura 1) se depreciaron. Como resultado, muchas industrias han suspendido su producción ya que esta no es rentable con los precios actuales de venta.

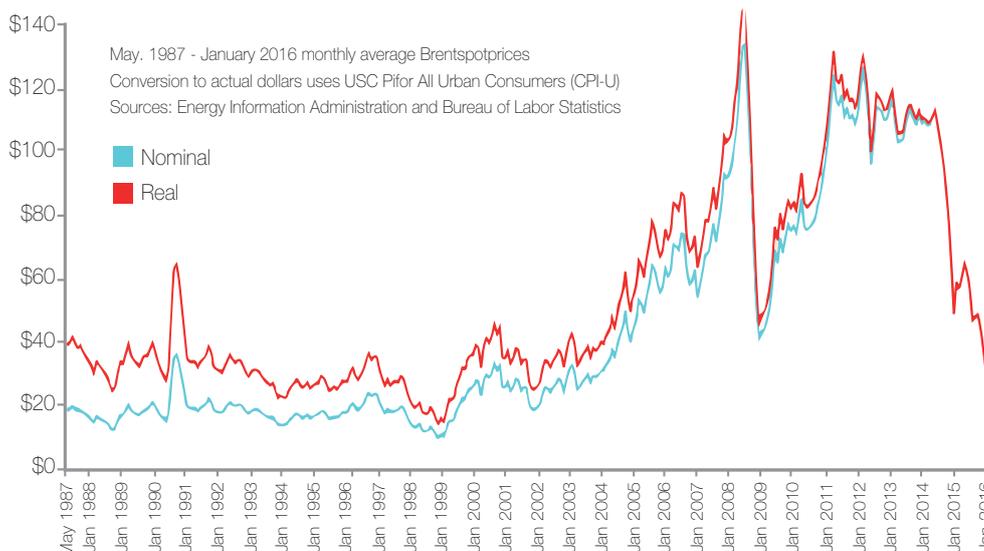


### Palabras Clave

Redes neuronales artificiales (RNA), predicción, consumo, combustible.

### Key words

Artificial Neural Networks (ANN), prediction, consumption, fuel.



**Figura 1.** Precios internacionales del barril de petróleo Brent de mayo de 1987 a junio de 2016.  
**Fuente:** Energy Information Administration and Bureau of Labor Statistics.

Mediante la reducción de costos se logra elevar el margen de ganancia de una empresa, el cual puede servir de amortiguador en diferentes tipos de situaciones: es posible bajar los precios frente a otros competidores para captar un mayor mercado, o ajustarse a la coyuntura y evitar ser desplazado o eliminado.

En el rubro de distribución de combustibles (R500, GLP, GNC, Diésel, etc.) existen diferentes problemas al momento de optimizar costos. Tal vez el que tiene mayor influencia y el más complicado de resolver es el eficiente uso de los recursos de los que se dispone. Para brindar un servicio de calidad y mantener los riesgos al mínimo es muy común que las empresas tiendan a sobredimensionar los recursos necesarios para operar de la mejor manera. En caso de que no puedan permitirse económicamente hacerlo, el servicio que ofrecen es muy deficiente con una calidad por debajo de la esperada. Es muy simple conducir un análisis de los tiempos muertos y tiempos de utilización de cada recurso, realizar el cálculo empírico y nominal de la capacidad de producción que tiene cada uno de los recursos, así como del tiempo y la frecuencia de los mantenimientos requeridos para que todo funcione adecuadamente. De tal manera, se puede comprobar si existe la posibilidad de mejorar u optimizar las operaciones.

La necesidad de optimizar recursos y tomar las decisiones más convenientes solo puede ser sustentable con la planificación. Sin embargo, si pudiéramos anticiparnos (principal objetivo de la predicción) y ser capaces de conocer con bastante precisión el ritmo futuro de trabajo, podríamos sincronizar los recursos para cubrir los requerimientos y ejecutar las actividades necesarias en el momento oportuno; así por ejemplo: los mantenimientos de las unidades pueden ser programados en los intervalos en los que existirá una baja demanda, puedan realizarse inspecciones y estar preparados antes de un incremento en la demanda, y que todas las necesidades sean agilizadas o ajustadas sin afectar el ciclo logístico para tener un mejor control de las operaciones.

Adicionalmente, la realización de simulaciones con las futuras demandas permite que, ante cualquier eventualidad, se planteen diferentes estrategias operativas para resolver o minimizar el impacto de los eventos perjudiciales. Asimismo, es posible contar con diversas estrategias para distintos escenarios, en las que se evaluará riesgo y costo económico, las cuales podrán ser diseñadas y ejecutadas de forma rápida, simple y con un sustento sólido.

En este contexto, el objetivo principal de esta investigación es predecir con un mínimo margen de error la demanda de combustible de las industrias de una forma rápida y sencilla (mediante el análisis de los patrones de consumo de cinco industrias de diferente funcionamiento por medio de redes neuronales) teniendo en cuenta que el consumo de combustible está directamente relacionado con la utilización de la maquinaria de una industria.

## FUNDAMENTOS

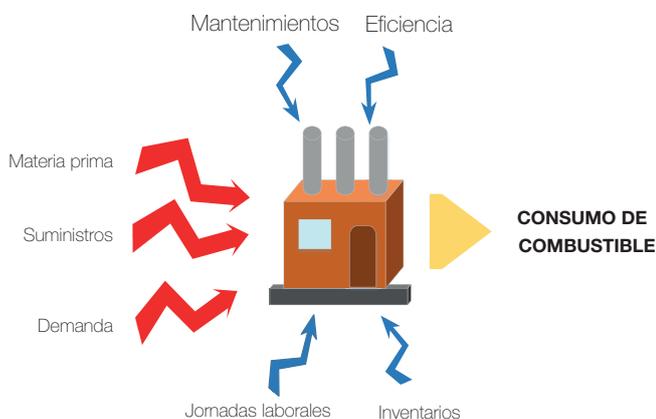
La predicción con series temporales estima valores futuros a partir de una secuencia de observaciones pasadas mediante diversas técnicas como las redes neuronales o descomposiciones de Fourier. Al respecto, existen diferentes trabajos orientados a la predicción de consumos, tanto de combustibles como de energía eléctrica, la mayoría enfocada a problemas prácticos que han sido analizados de manera detallada con resultados muy prometedores.

Se realizó un estudio [1] presentado por Energas (Ente Nacional Regulador del Gas, Argentina) para la predicción de consumo de gas natural a mediano y corto plazo, en el cual se incluía los consumos residenciales, industriales, GNC, etc. [2]. La predicción a corto plazo se enfocaba en los siguientes de 1 a 5 días mientras que el horizonte de la de mediano plazo era de 1 a 5 años. La metodología tomaba en consideración la temperatura

ambiental como uno de los factores altamente relacionados al consumo, y el posible error de los resultados fue del orden del 10%. El fundamento de la predicción residía en escenarios térmicos preferentemente de los últimos 30 a 40 años, con los que era posible determinar la probabilidad de que se volvieran a repetir. Según un análisis sistemático, el modelo sigue los datos observados en el 90% de los días con desviaciones inferiores al 10%. En este estudio se emplearon las transformadas de Fourier que se aplicaron a diferentes regiones de Argentina.

Otro estudio [5], enfocado en el uso de minería de datos, intenta predecir el consumo energético en la Universidad de León en un grupo de 30 edificios considerados de consumo elevado. Con este fin se implementa una arquitectura de triple capa, transparente y modular, aplicable al análisis de diferentes tipos de consumos energéticos (sistemas eléctricos, de calefacción o refrigeración). Además, se recogen datos de variables ambientales que influyen en el nivel de consumo. Luego de analizar esa información e interpretar los resultados, se generan predicciones. Adicionalmente, se propusieron métodos para la predicción del consumo eléctrico a corto (1 día) y mediano plazo (1 mes).

La predicción de los consumos que describiremos se realiza con ayuda de redes neuronales artificiales, para lo cual se define una metodología aplicable a diferentes empresas que tienen entornos operativos distintos. Dado que el propósito de la predicción es la toma de decisiones y el planteamiento de estrategias operativas, se contempla un plazo corto (brindar predicciones para cada dos horas) y mediano (horizonte de varios días). En razón de su asociación la logística de las empresas, la metodología debe poder utilizarse en conjunto con otras empleadas en estrategias operativas.



**Figura 2.** Variables que afectan el consumo de combustible.

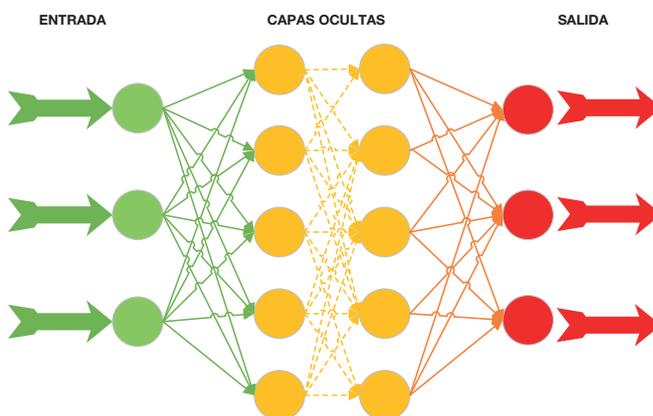
Puesto que el consumo de combustible por hora de una industria está sujeto a variables tanto externas como internas (Figura 2). Su predicción en muchos casos puede no seguir un comportamiento lineal o ser fácil de diagnosticar. La limitación del estudio recae en industrias que no poseen ningún patrón de producción (uso de máquinas que cambian continuamente; los productos que desarrollan son a pedido, y de características únicas; habilitación y deshabilitación de productos de forma completamente aleatoria), si la industria no presenta ningún patrón será imposible encontrar un tipo de tendencia en consumo por lo tanto su consumo no podrá ser predicho.

Si a lo anterior se agrega el hecho de que la aplicación en diferentes industrias implica que se tienen diversos productos, procesos heterogéneos, distintas máquinas y empresas en diferentes ubicaciones, la metodología a aplicarse debe ser lo suficientemente robusta para poder manejar las perturbaciones que afectan directa e indirectamente la predicción.

## METODOLOGÍA

Las redes neuronales artificiales son consideradas un instrumento y un método para la aproximación de funciones y comportamientos no lineales. Su utilidad en el modelamiento de fenómenos complejos ha permitido su aplicación en diferentes campos [4].

La estructura de una red neuronal artificial está compuesta de datos de entrada, neuronas en capas (si hay más de una se llama red neuronal multicapa) ocultas y datos de salida (Figura 3).



**Figura 3.** Red neuronal artificial multicapa.

Debido a la cantidad de factores que pueden afectar el consumo de una industria, se utiliza la metodología conocida como caja negra, que consiste en realizar el análisis sin saber que ocurre dentro de dicha caja (todo lo que ocurre dentro es desconocido para nosotros); es decir, solo nos basaremos en los datos de entrada y de salida sin darle importancia a lo que ocurra entre estos dos datos. Para este estudio se emplean redes neuronales artificiales. Así, el esquema de análisis quedaría de la forma planteada en la Figura 4. En ella se observan tipos de datos de entrada que serían los consumos registrados antes de la predicción y los identificadores, así como los datos de salida, definidos como los consumos pronosticados para las siguientes 24 horas.



**Figura 4.** Aplicación de la metodología de la caja negra.

Como todo proceso de entrenamiento (procedimiento por el cual se preparan las neuronas artificiales para su funcionamiento), para que el sistema realice una predicción de los consumos debemos proporcionar la información necesaria para llevar a cabo dicho análisis; es decir, suministrar menos datos de los requeridos no permite que las respuestas sean lo suficientemente precisas, y proveer datos adicionales que no estén relacionados hace que el sistema entre en corrupción (que el sistema brinde datos que no corresponden) y se aleje de la precisión deseada. Al tomar en consideración que existen diferentes métodos de análisis respecto a la inferencia y grado de relevancia de los datos de entrada, es necesario recordar que el enfoque de esta metodología apunta a ser aplicada en diferentes industrias. Por lo tanto, si alguna de ellas no posee de todos los datos de entrada requeridos, queda descartada (si para alguna industria no es relevante la proximidad de un feriado para la predicción, no se tomará en cuenta). Los datos adicionales a los consumos registrados del histórico los llamamos identificadores (Figura 4), y deben ser aplicables en cualquier industria.

Cada industria tiene sus propias políticas de confidencialidad, pues limita el acceso a los datos que podremos utilizar, por lo tanto se utilizarán datos de dominio público. La forma como definimos los identificadores son:

- Hora del día a predecir.
- Día de la semana a predecir.
- Cercanía del día a analizar de un feriado.
- Proximidad del día a analizar de la mitad de mes.
- Proximidad del día a analizar de fin de mes.
- Cercanía de los días del histórico a un feriado.
- Cercanía de los días del histórico a la mitad de mes.
- Proximidad de los días del histórico a fin de mes.

Para la red neuronal se utilizan 180 entradas que incluyen los consumos anteriores y los identificadores. La salida arroja 12 datos que estiman la proyección de consumo por cada dos horas; es decir, corresponden al consumo de las siguientes 24 horas. Se usan dos capas, una de neuronas 10 y otra de 12 neuronas, y el entrenamiento se efectúa por medio de Back Propagation (un algoritmo de entrenamiento de redes neuronales que en base a un patrón inicial este se propaga desde la primera capa a través de las capas siguientes de la red, hasta generar una salida que compara la señal de salida con la de salida deseada y se calcula una señal de error para cada una de las salidas). Dado que tenemos el histórico de los consumos de las industrias, se realiza un procesamiento adicional de los datos para obtener el promedio del consumo de cada industria que identifica cada día y cada hora, y luego calcula cuál es la variación fraccionaria respecto a este promedio (ecuación 1). Por lo tanto, la predicción se ajusta a este factor de corrección, el cual al ser multiplicado por el promedio de consumo de un día y hora determinados brinda el consumo esperado. Ello hace posible trabajar independientemente de las unidades en las que se mide el consumo. Para evitar problemas como falsas lecturas, picos

de consumo u otros, los consumos que se calculan y se retienen para el diagnóstico son el los de cada dos horas.

$$\text{Factor de corrección} = \frac{\text{Consumo actual}}{\text{Promedio de históricos de consumo}} \quad (1)$$

Consideremos un ejemplo práctico, en el cual el promedio de consumo histórico de una industria de dos periodos consecutivos es 400 y 420, y el valor de consumo real es de 320 y 380, respectivamente (las unidades pueden ser medidas en galones, litros, MBTU, calorías, etc.). En este caso, los factores de corrección para el primer consumo (ecuación 2) y el segundo consumo (ecuación 3) serían:

$$\text{Factor de corrección} = \frac{320}{400} = 0.8 \quad (2)$$

$$\text{Factor de corrección} = \frac{380}{420} = 0.905 \quad (3)$$

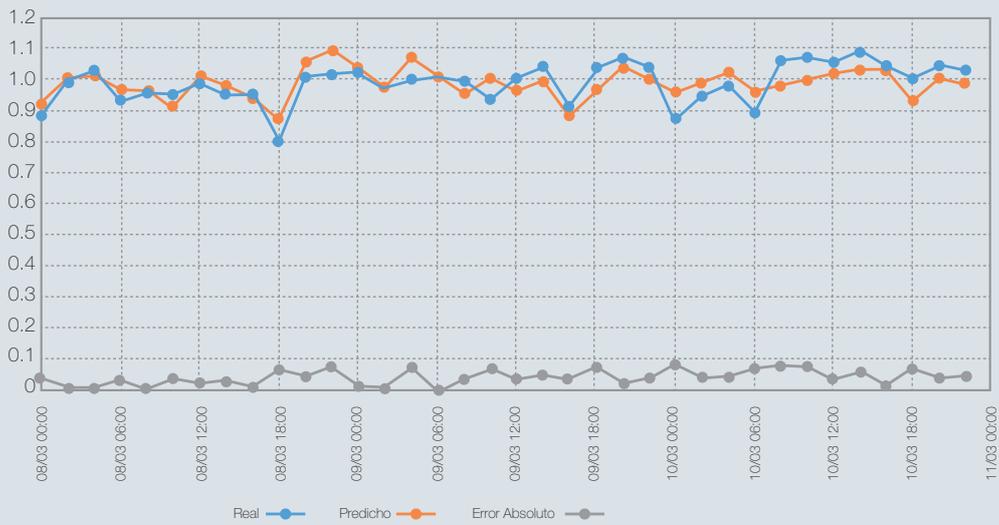
El factor de corrección sería mayor a 1 si el consumo actual supera al promedio de los históricos de consumo del cliente para el periodo de tiempo correspondiente, en tanto que sería menor a 1 si el consumo actual es menor al promedio histórico respectivo. Además, si logramos estimar el factor de corrección para los dos periodos antes mencionados podríamos transformarlos en el consumo actual pertinente (ecuación 4) con sus unidades respectivas.

$$\text{Consumo actual} = \text{Factor de corrección} * \text{Promedio de históricos de consumo} \quad (4)$$

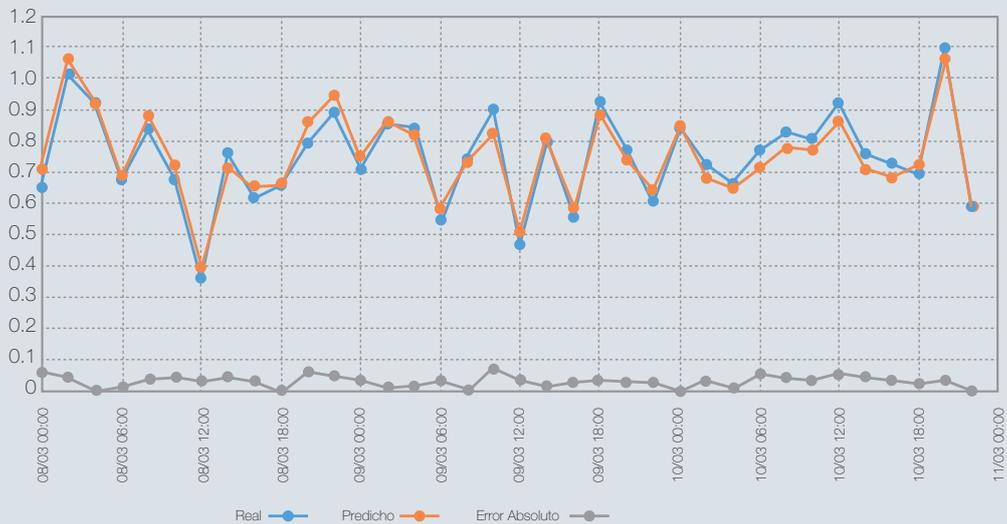
## RESULTADOS

Después del entrenamiento respectivo con el histórico de dos años y sus respectivos identificadores genéricos (los 180 datos de entrada incluyen los consumos de las últimas dos semanas y los identificadores del día a predecir) se procedió a comparar los valores pronosticados con los observados. En las siguientes gráficas (Figura 5 a Figura 9) se muestra la comparación de 72 horas de predicción tomando el consumo proyectado cada dos horas para las diferentes industrias, cada una con diferentes rasgos característicos respecto al consumo real de combustibles. Asimismo, para todas las series de datos, el error absoluto es calculado como el valor absoluto de la diferencia entre el valor de corrección real y el predicho. Cabe resaltar que el periodo de observación de 72 horas empezó el 8 de marzo del 2017 a las 00:00 horas (huso horario de la respectiva industria) y culminó el 11 de marzo del 2017 a la 00:00.

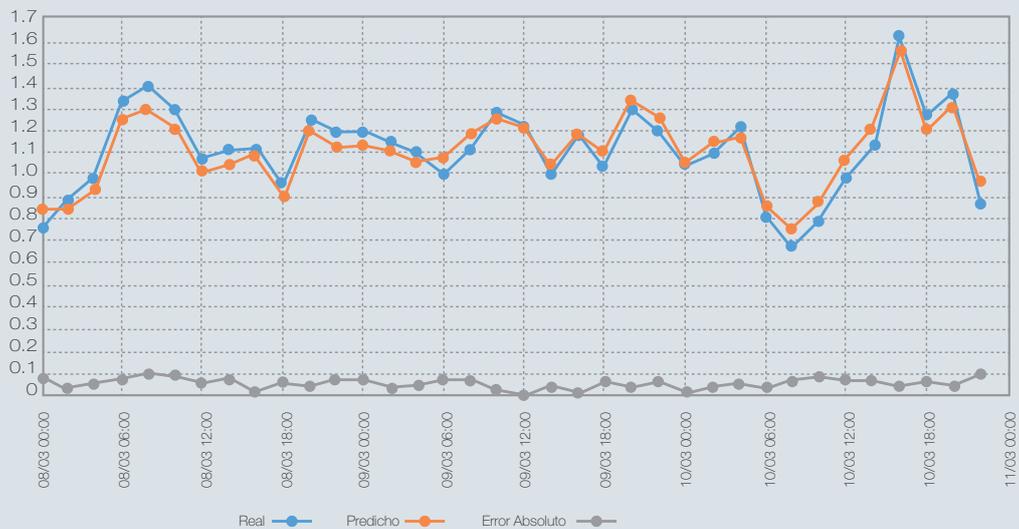
En la Industria 1 (Figura 5) se objetiva un consumo relativamente estable, ya que el factor de corrección no muestra grandes variaciones.



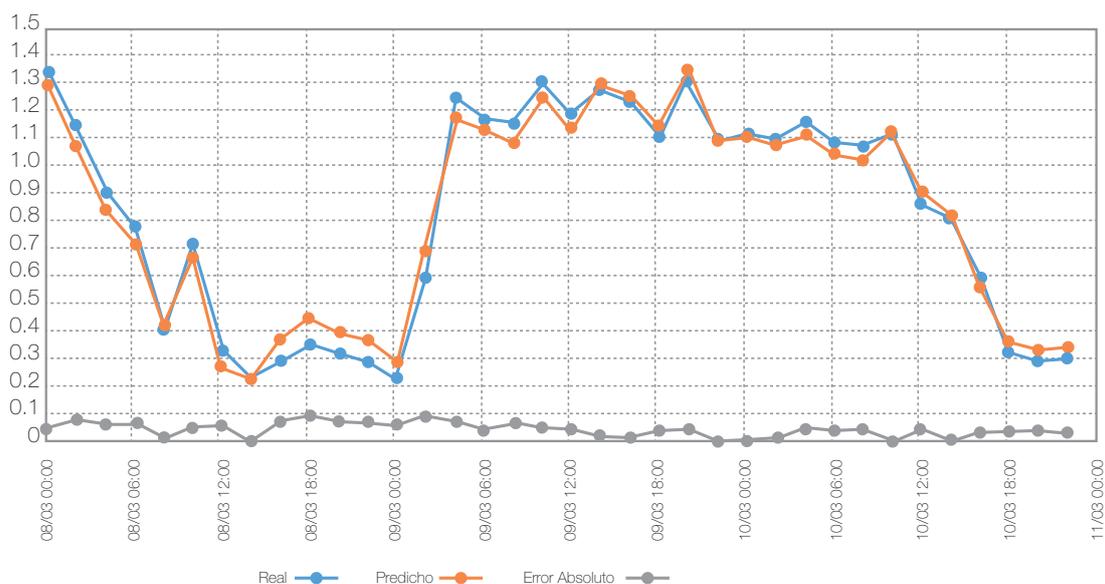
**Figura 5.** Comparación entre los valores reales y los valores predichos en la Industria 1.



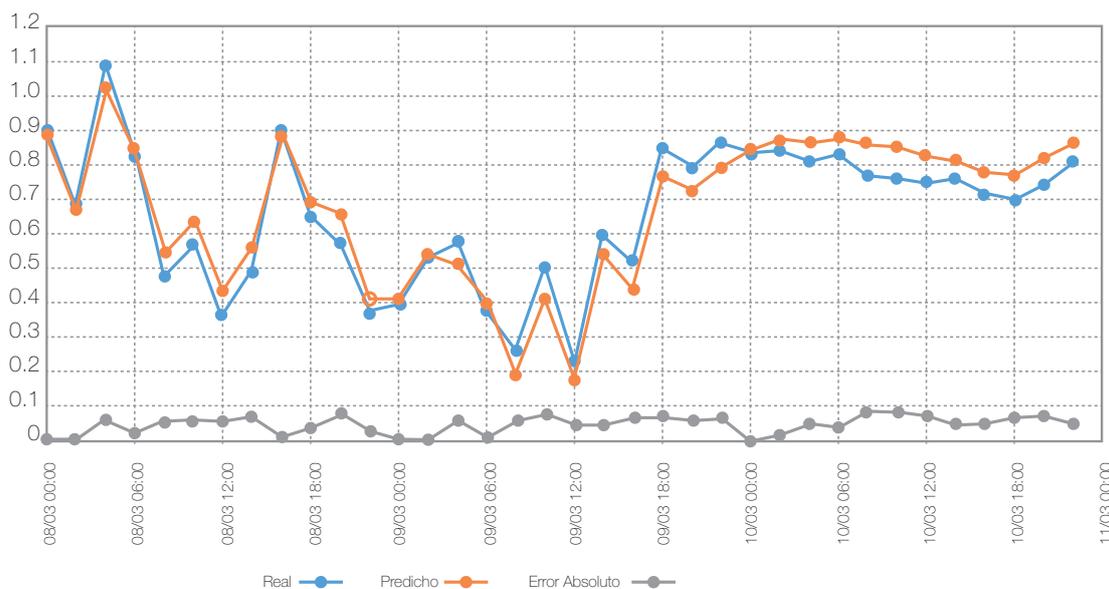
**Figura 6.** Comparación entre los valores reales y los valores predichos en la Industria 2.



**Figura 7.** Comparación entre los valores reales y los valores predichos en la Industria 3.



**Figura 8.** Comparación entre los valores reales y los valores predichos en la Industria 4.



**Figura 9.** Comparación entre los valores reales y los valores predichos en la Industria 5.

En las gráficas correspondientes a los resultados de las industrias 2, 3, 4 y 5 se observa que los factores de corrección no son tan uniformes como en el caso de la Industria 1 (Figura 5). Sin embargo, las predicciones siguen muy estrechamente las tendencias de los valores reales.

El empleo del factor de corrección y no del valor del consumo, permite la estimación relativa del consumo de cada industria (no es lo mismo un error de 50 galones cuando el consumo es de 70 o de 500) de manera que los resultados son aplicables a la especialidad de cada industria.

Cuando se compara el análisis del consumo promedio diario predicho y el observado de las industrias estudiadas (Figura 10) para determinar si el grado de precisión de la predicción disminuye significativamente para un periodo de alcance temporal mayor (diario), podemos constatar que el error del factor de corrección es incluso menor que para el caso anterior, de horizonte temporal más corto (de horas).



Figura 10. Comparación del error absoluto en la predicción de 24 horas en las industrias estudiadas.

## CONCLUSIONES

- Se implementó una metodología con resultados muy aceptables (error absoluto máximo del 10% en corto plazo y 6% en mediano plazo) basada en el uso de redes neuronales artificiales compatibles con industrias de ciclo de producción continuo.
- Se comprobó que las redes neuronales artificiales son una herramienta muy poderosa y de aplicación simple para la predicción de datos.
- Datos de entrada correctos son vitales para plantear un sistema de redes neuronales artificiales, ya que realizar un entrenamiento con información no relevante puede producir resultados con errores significativos.
- La metodología utilizada es lo suficientemente general para ser aplicable con diferentes industrias.
- Cuando se requiera mayor precisión en las predicciones, habría que estudiar independientemente cada caso con el fin de agregar datos de entrada que sean característicos de cada industria. Sin embargo, ello no es compatible con el planteamiento de una metodología general para diferentes industrias.
- Es posible realizar la predicción de consumos con una precisión aceptable en industrias que poseen un régimen de producción relativamente continuo. Si el objeto de estudio es una industria de producción por lotes y por pedido deberán incluirse datos adicionales a la entrada ya que los datos de identificación convencionales utilizados serían demasiado genéricos para este tipo de casos.
- Gracias a la precisión y naturaleza de las predicciones, es posible emplearlas en conjunto para optimizar las operaciones dentro de una industria, o mejorar el servicio de entrega o suministro de combustibles a dicha industria, independientemente de que la predicción del consumo tenga un horizonte de corto o mediano plazo.

## REFERENCIAS

- [1] Gil, S., Deferrari, J., & Duperron, L. (2002). Modelo generalizado de predicción de consumos de gas natural a mediano y corto plazo. *3er. Congreso Latinoamericano y del Caribe de Gas y Electricidad, Instituto Brasileiro de Petróleo e Gás*, Santa Cruz de la Sierra – Bolivia.
- [2] Gil, S. & Deferrari, J. (1999). Modelo de predicción de consumo de gas natural en la República Argentina. *Petrotecnia, Revista del Instituto Argentino del Petróleo y del Gas*, XL(3), 27-32.
- [3] Haidar, J. (2012). Impact of Business Regulatory Reforms on Economic Growth. *Journal of the Japanese and International Economies* 26(3), 285-307.
- [4] Heinemann, M. (2000). Adaptive learning of rational expectations using neural networks. *Journal of Economic Dynamics and Control*, 24(5-7), 1007-1026.
- [5] Morán, A. (2012). *Análisis y predicción de perfiles de consumo energético en edificios públicos mediante técnicas de minería de datos* (Tesis Doctoral), Universidad de Oviedo, España.

## ACERCA DEL AUTOR

### Gonzalo Eduardo Aragón Polanco

Profesional técnico en Mantenimiento de Maquinaria Pesada por Tecsup. Candidato al título de Ingeniero Mecatrónico por la Universidad Católica de Santa María, Arequipa. Experiencia de dos años en operaciones y logística en la entrega de gas natural.

@ g-aragon@hotmail.com