

# Nariz electrónica: Herramienta para detección de gases empleando redes neuronales artificiales.

## Electronic nose: Tool for gas detection using Artificial Neural Networks.

Carlos Eduardo Carbajal Peñaloza (1).  
Tecnológico de Estudios Superiores de Ecatepec, Estado de México, México.  
[kamued@gmail.com](mailto:kamued@gmail.com)

Abraham Jorge Jiménez Alfaro (2), Tecnológico de Estudios Superiores de Ecatepec, [ajja\\_mx@yahoo.com](mailto:ajja_mx@yahoo.com).

Édgar Corona Organiche (3), Tecnológico de Estudios Superiores de Ecatepec, [organiche2003@yahoo.com.mx](mailto:organiche2003@yahoo.com.mx).

Noel Enrique Rodríguez Maya (4), Instituto Tecnológico de Zitácuaro, Tecnológico Nacional de México, Zitácuaro, Michoacán, [nrodriguez@itzitacuaro.edu.mx](mailto:nrodriguez@itzitacuaro.edu.mx).

Artículo recibido en julio 30, 2018; aceptado en septiembre 10, 2018.

### Resumen.

*En este artículo se presenta un prototipo de una nariz electrónica a través de un sistema de adquisición de datos, utilizando la plataforma de Arduino Mega 2560 la cual usa los sensores MQ-2, MQ-3, MQ-7 y MQ-135. El sistema está habilitado para analizar diferentes niveles de gas licuado del petróleo (LP) establecidos a través de un modelo de clasificación basado en Redes Neuronales Artificiales (RNA). Los resultados mostraron un modelo capaz de detectar niveles de olor con una precisión del 99.8% en tiempo real.*

**Palabras clave:** Redes Neuronales Artificiales, Sistema de Adquisición de Datos, Nariz electrónica, Sistemas de tiempo real.

### Abstract.

*This article presents a prototype of an electronic nose which works through a data acquisition system, using the Arduino Mega 2560 platform and MQ-2, MQ-3, MQ-7 and MQ-135 sensors. The system is able to analyze different levels of liquefied petroleum gas (LP) which were established by a classification model based on Artificial Neural Networks (ANN). The results showed that the model detects odor levels with an accuracy of 99.8% in real time.*

**Keywords:** Artificial Neural Networks, Data Acquisition System, Electronic nose, Real-time systems.

## 1. Introducción.

El gas LP es un combustible utilizado en una gran cantidad de actividades como en el hogar y en la industria; por ejemplo, en el hogar se utiliza para cocinar, para calentar agua para aseo personal, también se usa como combustible en los automóviles, etc. El problema del uso del hidrocarburo radica en que su manejo y exposición es peligroso, si escapa a la atmósfera se pueden formar nubes inflamables y explosivas o si una persona inhala el gas durante un tiempo prolongado puede resultar intoxicada.

La nariz electrónica es una investigación que se ha venido consolidando en las últimas décadas, con el fin de ser aplicado en casi todos los sectores (por ejemplo, salud, procesamiento de productos, control de calidad, industria química,

entre otros) (Gualdrón et al., 2014). Los orígenes de las narices se remontan desde los años 60 cuando la compañía Bacharac Inc., construyó un prototipo llamado *Sniffer*, el cual contaba con un sólo sensor. Con el paso del tiempo la tecnología de las narices electrónicas fue evolucionando, consiguiendo potentes herramientas de clasificación y detección de aromas, lo que derivó en una gran expansión de mercado en diferentes ámbitos de negocios (Moreno et al, 2009). Todos estos avances han dado lugar a la fabricación comercial de narices electrónicas. La mayoría de las narices electrónicas diseñadas hasta la fecha son para uso comercial, algunas otras son utilizadas por los gobiernos para seguridad y otras son usadas en equipos hospitalarios. La mayoría de estos proyectos usan reconocimiento de patrones (Ávila, 2013).

En este trabajo de investigación se presenta el diseño de un prototipo de una nariz electrónica para obtener datos en tiempo real sobre la detección de olores de gas LP, con la finalidad de alertar la presencia del gas mostrando en pantalla el nivel en que se encuentra en cada una de las pruebas correspondientes. Esto a través del apoyo de elementos como la plataforma Arduino 2560, sensores de gas MQ-2 y MQ-3, MQ-7 y MQ-135.

## 2. Métodos.

### Redes Neuronales Artificiales.

Las Redes Neuronales Artificiales (RNA) están inspiradas en las redes neuronales biológicas del cerebro humano; están constituidas por elementos que se comportan de forma similar a la neurona biológica en sus funciones más comunes. Estos elementos están organizados de una forma parecida a la que presenta el cerebro humano (Matich, Ruiz, Basualdo, 2001). El rendimiento de los modelos basados en RNA -para determinar compuestos químicos detectables- generalmente se ven beneficiados con el uso de matrices de sensores de gas que con el uso de un solo sensor. Por lo que se pueden utilizar un conjunto de sensores con menor costo. El objetivo del proceso de entrenamiento o configuración de una RNA es la generación de modelos de clasificación para determinar diferentes niveles de saturación de gas LP e implementar un sistema identificador de olores automatizado (Keller, 1999). Una vez generado el clasificador, se le puede introducir diferentes entradas (gases o olores con compuestos químicos específicos) y el modelo determina el tipo de gas en tiempo real (Keller, 1999).

### Matriz de sensores.

El MQ-2 es un sensor de gas compuesto por un micro tubo cerámico  $AL_2O_3$ , una capa sensible dióxido de estaño ( $S_nO_2$ ), un electrodo de medición, un calentador y una malla de acero inoxidable. El calentador ofrece condiciones de trabajo necesarias para el trabajo de los componentes sensibles. El MQ-2 consta de 6 pines, 4 de ellos se utilizan para de señales y los restantes se utilizan para proporcionar la corriente de calentamiento. El sensor obtiene las concentraciones de los gases  $H_2$ ,  $C_3H_8$ ,  $C_4H_{10}$ . El sensor MQ-3 (sensor de alcohol) está compuesto por un micro tubo de cerámica  $AL_2O_3$ , por una capa delgada de  $SnO_2$ , el electrodo de medición y el calentador son fijados a una corteza de plástico y una red de acero inoxidable. El sensor puede medir varias concentraciones de gases ( $C_6H_6$ ,  $C_2H_6O$ ) principalmente el alcohol. El MQ-7 es un sensor sensible al monóxido de carbono (CO) y al dihidrógeno ( $H_2$ ). El MQ-135 está diseñado para medir la calidad del aire, es utilizado en equipos de control de calidad del aire para edificios y oficinas, es adecuado para detectar amoníaco ( $NH_3$ ), óxidos de nitrógeno (NOx), alcohol, benceno, humo,  $CO_2$ , entre otros (Rubio et al., 2015). Los sensores deben estar localizados en una cámara aislante que garantice las condiciones óptimas para una operación adecuada (Brezmes, 2000). La Tabla 1 muestra la lista de los sensores de gas utilizados en este arreglo.

**Tabla 1.** Sensores de Gas de la Nariz Electrónica

Sensor	Compuestos químicos
MQ-2	$H_2$ , LPG, $CH_4$ , CO
MQ-3	Alcohol, Benceno, $CH_4$ , Hexano
MQ-7	Monóxido de Carbono, $H_2$
MQ-135	$NH_3$ , NOx, alcohol, benceno, humo, $CO_2$

### Nariz electrónica.

En la literatura se pueden encontrar diferentes métodos y técnicas para determinar aromas, olores y gases aplicados

en diferentes dominios, como son: en la industria alimenticia, en la elaboración de cosméticos, en la domótica, en la rama automotriz, entre otros (Durán, 2013). Una Nariz Electrónica (NE) es una herramienta de medición, la cual está compuesta de una matriz de sensores químicos, los cuales permiten obtener datos del ambiente y a través de diferentes técnicas, son capaces de identificar una variedad de olores simples o compuestos previamente definidos (sensibilidades parcialmente sobrepuestas) (Hernández, Galaviz, 2006) (Durán, 2013).

La Figura 1 muestra el prototipo de NE, la cual consta de los siguientes elementos:

- Cámara de concentración de gas, con sensores de gas.
- Circuito de control con Arduino Mega 2560.
- Laptop para análisis de datos.



**Figura 1.** Prototipo de NE de gas LP.

### 3. Desarrollo.

#### **Captura de datos.**


En la primera parte se llevó a cabo el “pre-procesado de la señal”, la cual incluye las siguientes actividades: compensación de la deriva de los sensores, extracción de los parámetros descriptivos de la respuesta del arreglo de sensores y la preparación del vector de características para el posterior procesamiento (Lozano et al., 2004). Para realizar la adquisición del conjunto de medida de entrenamiento fue empleado el compuesto volátil gas LP.

El algoritmo seleccionado para el entrenamiento de la red neuronal es Backpropagation (BP). Este algoritmo de entrenamiento es el más conocido en las redes neuronales multicapa y es la red más flexible de implementar en hardware, y que se definen las reglas de propagación del error desde la salida hasta las unidades de entrada de la red y el ajuste de los pesos (Song et al., 2011) (Benrekia, Attari, 2013).

La tarjeta Arduino Mega 2560 captura los valores de voltaje proveniente de cada uno de los sensores, una vez obtenida cada una de las muestras se exporta a un archivo para realizar con la normalización de los datos; en el caso de un sistema de sensores en Arduino, el rango de entrada de los datos está definido entre 0 y 1024. La normalización trata básicamente de uniformizar todos los rangos de números a un único rango de valores entre 0 y 1 (o entre -1 y 1) de números flotantes (Melendez, 2015). El proceso de normalización se realizó en una hoja de cálculo (Microsoft Excel), una vez obtenidos los datos normalizados se procedió a entrenar la red neuronal.

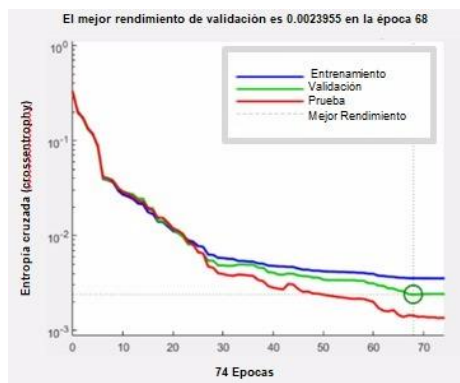
#### **Generación y validación del modelo.**

La siguiente etapa es la validación del modelo, para esto se analizó la matriz de confusión obtenida la cual mostró una precisión del 98%. La Figura 2 muestra diferentes matrices de confusión obtenidas: matriz de confusión para el entrenamiento, la validación y prueba. Las pruebas que se realizaron fueron: sin gas, concentración media de gas y concentración alta de gas.



**Figura 2.** Matriz de confusión obtenida.

La figura 3 muestra el rendimiento del modelo generado utilizando la técnica de cross-entropy; se puede observar que el mejor rendimiento para el caso de validación fue de 0.0023955 obtenida en la época 68.



**Figura 3.** Rendimiento de la Red Neuronal.

La figura 4 se observa un histograma de frecuencias del error obtenido al dividir el dataset en 20 bins.




Figura 4. Histograma Red Neuronal.

La validación y el gradiente del entrenamiento se muestra en la figura 5, se puede observar el comportamiento del entrenamiento, obteniendo el mejor desempeño en la época 74.

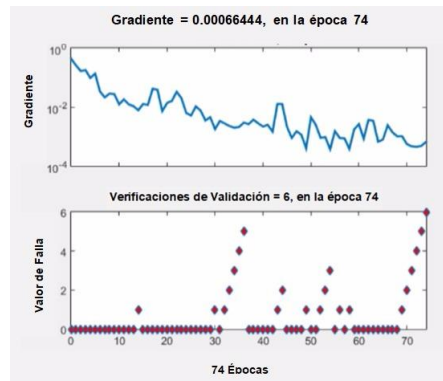


Figura 5. Estado de entrenamiento.

La figura 6 muestra las gráficas de las curvas COR (Característica Operativa del Receptor) las cuales muestran claramente la sensibilidad entre los falsos positivos obteniendo una tendencia a 1.

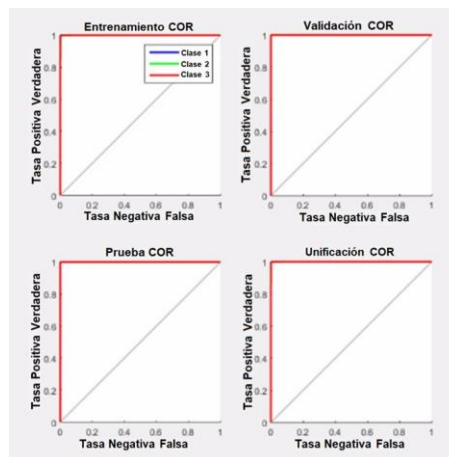


Figura 6. Curvas COR.

La figura 7 muestra la arquitectura de la RNA, la cual consta de: 2 neuronas de entrada, 1 capa oculta con 20 neuronas y 3 salidas.

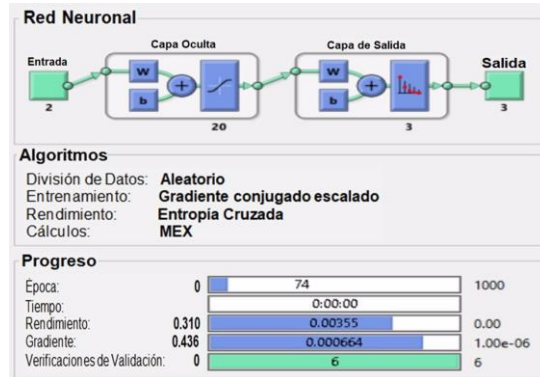


Figura 7. Herramienta de formación.

### 3. Resultados.

En esta sección se presentan los principales resultados de las pruebas realizadas; es importante mencionar que las pruebas se realizaron en un ambiente controlado. La primera prueba que se realizó, fue en un ambiente sin presencia de gas, la cual fue calculada por el modelo sin ningún problema, como se indica en la figura 8.

```
Command Window
New to MATLAB? Watch this Video, see Demos, or read Getting Started.

0.9995
0.0003
0.0006

No hay gas
```

Figura 8. Resultado sin detección de Gas LP.

La segunda prueba fue realizada en un ambiente con una concentración media de gas, teniendo como parámetro una liberación continua por un lapso de tiempo de 1 minuto del mismo; como se puede observar en la Figura 9, el modelo determinó con facilidad la presencia media de gas.

```
Command Window
New to MATLAB? Watch this Video, see Demos, or read Getting Started.

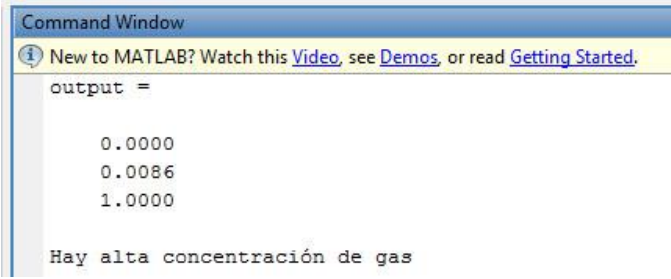
output =

0.0000
0.9997
0.0006

Hay concentracion media de gas
```

Figura 9. Resultado de concentración media de gas LP.

La tercera prueba fue realizada en un ambiente con una concentración alta de gas, después de 3 minutos se observó la salida del modelo como se observa en la Figura 10.



```

Command Window
New to MATLAB? Watch this Video, see Demos, or read Getting Started.
output =
    0.0000
    0.0086
    1.0000
Hay alta concentración de gas
  
```

**Figura 10.** Resultado de concentración alta de gas LP.

## Conclusiones.

A través del prototipo de Nariz Electrónica se generó un modelo de predicción basado en Redes Neuronales Artificiales (RNA) de presencia de saturación de gas LP. Se determinó en tiempo real la detección de olores por medio del Sistemas de Adquisición de Datos (DAS) y el modelo basado en RNA generado en el lenguaje de programación MatLab. Con el uso del algoritmo de *Backpropagation* para el entrenamiento de la RNA se pudo obtener un modelo de predicción confiable con una precisión de más del 98%. El prototipo generado, además de económico, resulta de gran ayuda en la detección de saturación de gas LP.

## Referencias Bibliográficas.

- Ávila, J. (2013) Implementing an Electronic Nose for Organic Matter Detection in Garbage. *Conference: 2nd International Conference on TI*. Tlaxcala, Tlaxcala. Vol. 1. Año 2013.
- Benrekia, F., Attari, M., Bouhedda, M. (2013) Gas sensors characterization and multilayer perceptron (MLP) hardware implementation for gas identification using a field programmable gate array (FPGA). *Sensors*, 13 (3), pp. 2967-2985. Año 2013.
- Brezmes, J., Llobet, E., Vilanova, X., Saiz, G., Correig, X. (2000) Fruit ripeness monitoring using an electronic nose. *Sensors and Actuators B: Chemical*, 69(3), 223-229. 2000.
- Durán, Acevedo, C.M. (2013) Optimización de una nariz electrónica a través de un método de selección de variables. *Revista: El Hombre y la Máquina*, núm. 41, enero-abril, 2013, pp. 56-63 Universidad Autónoma de Occidente Cali, Colombia.
- Gualdrón, Guerrero, O. E., Durán, Acevedo, C. M., Araque, Gallardo, J. A., Ortíz-Sandoval, J. E. (2014) Implementación de un modelo neuronal en un dispositivo hardware (FPGA) para la clasificación de compuestos químicos en un sistema multisensorial (nariz electrónica). *Revista Colombiana de Tecnologías de Avanzada*. ISSN: 1692-7257. Volumen 2. Número 24. Año 2014.
- Hernández, C. T. R., & Galaviz, O. F. R. (2006) Clasificación de Datos de Olor de Café provenientes de una Nariz Electrónica Utilizando Redes Neuronales. *Universidad Autónoma de Tlaxcala*. 2016.
- Keller, P. E. (1995) Electronic noses and their applications. In *Northcon 95. IEEE Technical Applications Conference and Workshops Northcon95* (p. 116). IEEE. October 1995.
- Keller, P. E. (1999) Overview of electronic nose algorithms. In *Neural Networks, 1999. IJCNN'99. International Joint Conference on* (Vol. 1, pp. 309-312). IEEE. 1999.
- Lozano, J., García, A., García, C. J., Aleixandre, M., Santos, J. P., & Horrillo, M. C. (2004) Reconocimiento de patrones basado en redes neuronales y análisis de componentes independientes para narices electrónicas. *Universidad de Extremadura, Instituto de Física Aplicada, CSIC. España, 2004*.

- Matich**, D. J., Ruiz, C. A., Basualdo, M. S. (2001) *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Universidad Tecnológica Nacional – Facultad Regional Rosario Departamento de Ingeniería Química. Marzo 2001.
- Melendez**, D. A. (2015) Normalización de datos obtenidos mediante un sistema de adquisición de datos que emplea la plataforma arduino para el reconocimiento de patrones de olor mediante una red neuronal. *Universidad Da Vinci A.C., Diciembre, 2015*.
- Moreno**, I., Caballero, R., Galán, R., Matfá, F., Jiménez, A. (2009). La nariz electrónica: Estado del arte. *Revista Iberoamericana de Automática e Informática Industrial (RIAI)*. ISSN: 1697-7912. Vol. 6, Núm. 3, Julio 2009, pp. 76-91.
- Rubio**, J. D. J., Ortigoza, R. S., Avila, F. J., Melendez, A., & Stein, J. M. (2015). A fuzzy inference system for the identification. *IEEE Latin America Transactions*, 13(9), 2823-2829.
- Song**, K., Wang, Q., Liu, Q., Zhang, H., & Cheng, Y. (2011). A Wireless Electronic Nose System Using a Fe<sub>2</sub>O<sub>3</sub> Gas Sensing Array and Least Squares Support Vector Regression. *Sensors (Basel, Switzerland)*, 11(1), 485–505. <http://doi.org/10.3390/s110100485>

### Información de los autores.



**Carlos Eduardo Carbajal Peñaloza** es Ing. en Sistemas Computacionales por el Tecnológico de Estudios Superiores de Valle de Bravo, Estado de México, cuenta con Maestría en Ingeniería en Sistemas Computacionales por el Tecnológico de Estudios Superiores de Ecatepec, Estado de México. Labora en el ámbito privado internacional como Arquitecto de Soluciones para el sector de Telecom y TI en temas actuales de Transformación digital e Internet de las Cosas.



**Abraham Jorge Jiménez Alfaro** es Lic. en Ciencias de la Informática y Sistemas por la Unidad Profesional Interdisciplinaria de Ingeniería, Ciencias Sociales y Administrativas del Instituto Politécnico Nacional, tiene una maestría en Ciencias de la Computación por la Universidad Autónoma Metropolitana Campus Azcapotzalco y cuenta con un doctorado en Ciencias en Tecnologías de la Información y Comunicaciones de la Universidad Popular Autónoma del Estado de Puebla. Tiene la distinción de Perfil Deseable ante PRODEP y es Líder del Cuerpo Académico en Formación “Ciencias en Tecnologías de Información, Sistemas y Comunicaciones” del Tecnológico de Estudios Superiores de Ecatepec.





**Édgar Corona Organiche** es Lic. en Electrónica por la Universidad Autónoma de Puebla, tiene una maestría en Ciencia de Materiales por el Instituto de Física “Luis Rivera Terrazas” de la Universidad Autónoma de Puebla y cuenta con estudios de doctorado en Tecnología Avanzada en el Centro de Investigación en Ciencia Aplicada y Tecnología Avanzada del Instituto Politécnico Nacional. Tiene la distinción de Perfil Deseable ante PRODEP y es miembro del Cuerpo Académico en Formación “Ciencias en Tecnologías de Información, Sistemas y Comunicaciones” del Tecnológico de Estudios Superiores de Ecatepec.



**Noel Enrique Rodríguez Maya** es Ing. en Sistemas Computacionales por el Instituto Tecnológico de Zitácuaro, Michoacán, tiene una Maestría en Ciencias Computacionales por el Laboratorio Nacional de Informática Avanzada A.C. de Xalapa, Veracruz, cuenta con un Doctorado en Ciencias en Ingeniería Eléctrica opción Sistemas Computacionales por la División de Estudios de Posgrado de la Facultad de Ingeniería Eléctrica de la Universidad Michoacana de San Nicolás de Hidalgo. Tiene la distinción de Perfil Deseable ante PRODEP y es miembro del Cuerpo Académico en Formación "Sistemas Computacionales" del Instituto Tecnológico de Zitácuaro.