

## **Red neuronal Backpropagation para la predicción de datos de contaminación y prevención de ataques a personas con padecimientos de rinitis alérgica y asma**

Daniel Cerna-Vázquez<sup>1</sup>, Carlos Lino-Ramírez<sup>1</sup>, Arnoldo Díaz-Ramírez<sup>2</sup>,  
Juan Francisco Mosiño<sup>1</sup>, Miguel Ángel Casillas-Araiza<sup>1</sup>, Rosario Baltazar-Flores<sup>1</sup>,  
Guillermo Mendez-Zamora<sup>1</sup>

<sup>1</sup> Tecnológico Nacional de México, Instituto Tecnológico de León,  
León, Guanajuato, México

<sup>2</sup> Tecnológico Nacional de México, Instituto Tecnológico de Mexicali,  
Mexicali, Baja California, México

cerna.daniel.dc@gmail.com, carloslino@itleon.edu.mx, jfmosino@gmail.com,  
miguel.casillas@gmail.com, charobalmx@yahoo.com.mx, guillermomendez06@gmail.com,  
adiaz@itmexicali.edu.mx

**Resumen.** La prevención de enfermedades respiratorias causadas por los altos índices de contaminación ambiental, es un tema de importante discusión en las grandes ciudades, donde la industrialización y la sobrepoblación causan un incremento de partículas alérgicas que agravan el padecimiento de rinitis alérgica y asma, sobre todo en la comunidad infantil. El problema radica en la desinformación de la población acerca de la calidad del aire y las medidas preventivas a tomar en cuenta para evitar un deterioro en la salud. En este artículo, se presentan datos monitoreados por una red de sensores que registran cinco de los principales alérgenos para diferentes zonas de la ciudad de León, Guanajuato. Una red neuronal artificial (RNA) con un entrenamiento supervisado de tipo Backpropagation, es empleada para la predicción de datos futuros hasta alcanzar un error mínimo. Posteriormente, se emiten recomendaciones previamente avaladas, con base a los resultados arrojados por la red neuronal. La metodología propuesta genera resultados eficientes, medidos en el error de las soluciones y en tiempo de ejecución.

**Palabras clave:** redes de sensores, red neuronal artificial, entrenamiento backpropagation, predicción de datos climáticos.

### **Backpropagation Neural Network for the Prediction of Contamination Data and Prevention of Attacks to People with Allergic Rhinitis and Asthma**

**Abstract.** The prevention of respiratory diseases caused by high air pollution rates is an important issue in big cities, where industrialization and overpopulation cause an increase in allergenic particles that aggravate the disease

of allergic rhinitis and asthma, especially in childhood. The problem lies in the disinformation of the population about air quality and the preventive measures to be taken in order to avoid deterioration in health. In this paper, data are monitored by a sensor network that registers five of the main allergens for different areas of the city of León, Guanajuato. An artificial neural network (ANN) with a supervised Backpropagation training is used to predict future data until a minimum error is reached. Then, we emit approved recommendations, based on the results of the neural network. The proposed methodology generates efficient results, measured in the error of the solutions and in execution time.

**Keywords:** sensor network, artificial neural network, backpropagation training, climate data prediction.

## 1. Introducción

Una de las principales causas de enfermedades respiratorias y que genera gran preocupación para las grandes ciudades, es la emisión aérea de contaminantes, que es ocasionada por diversas actividades humanas, entre ellas, la industria [1], [2]. El empleo de recursos no renovables en la producción de energía, como el petróleo o el carbón, genera importantes emisiones de dióxido de azufre ( $\text{SO}_2$ ), monóxido de carbono (CO), entre otras. Por otro lado, los medios de transporte empleados en la vida cotidiana son otra fuente alarmante de contaminación. Una gran parte de estos contaminantes emitidos al ambiente es generada por los automóviles [3]. Según las Naciones Unidas, actualmente hay alrededor de 7 billones de personas en el mundo [4], [5], lo que representa una enorme fuente de contaminación, agravando el problema a medida que las personas tienden a migrar a grandes ciudades, lo que conlleva a una mayor emisión de contaminantes que deterioran la calidad del aire. Según datos del Consejo Nacional de Población (CONAPO), el 72.3% de la población en México, vive en zonas metropolitanas. Además, según la Organización de las Naciones Unidas (ONU), en los próximos 10 años las poblaciones rurales comenzarán a disminuir significativamente [6]. Esto genera que la salud de las personas, en las grandes ciudades, se deteriore cada vez más, ya que los individuos que viven en lugares con altos índices de contaminación son más propensos a adquirir enfermedades del tipo respiratorias, como alergias o asma [7].

Los alérgenos son aquellas partículas que pueden causar alergias y/o agravar el asma. Entre los principales alérgenos encontrados en el aire, se encuentran el ozono ( $\text{O}_3$ ), el dióxido de azufre ( $\text{SO}_2$ ), el monóxido de carbono (CO), el plomo (Pb), la materia particulada ( $\text{PM}_{2.5}$  y  $\text{PM}_{10}$ ), entre otros [8], [9]. El asma es una de las enfermedades que más afecta principalmente a la población infantil. A nivel escolar existe una prevalencia del 9.4% en los infantes a nivel mundial, y un 12.6% durante la adolescencia. De estos, el 80% presentan alergias con respecto al entorno en el que viven [10]. Según datos de la encuesta ISAAC, en México la prevalencia del asma va del 2.7% al 21.8% en diferentes ciudades. Para los infantes, la prevalencia fue del 5.7% y de 5.9% para los adolescentes [11]. La rinitis alérgica es una de las enfermedades crónicas más frecuentes a nivel mundial [12]. Este padecimiento es más frecuente en regiones con alto índice de tráfico vial. Esto se debe a que el aumento de la contaminación genera también un aumento en los síntomas de las personas que sufren

esta enfermedad [7]. En México, según el estudio ISAAC, existe una prevalencia del 4.6% de rinitis alérgica en infantes. La rinitis alérgica se puede agravar debido a los alérgenos que genera la contaminación y con esto llegar a generar asma [13].

El monitoreo constante de la calidad del aire, empleando redes de sensores [14], permite a las personas que sufren de rinitis alérgica y asma, mantenerse informadas acerca de las condiciones ambientales de su entorno, para así tomar acciones pertinentes y evitar un deterioro en la salud, por causa de los altos niveles de contaminación que les rodea. En la ciudad de León, Guanajuato, México, se cuenta con la monitorización de la calidad del aire por parte del Instituto de Ecología del Estado (IEE). El IEE cuenta con un Sistema de Monitoreo de Calidad del Aire del Estado de Guanajuato (SIMEG). El sistema está conformado por tres estaciones de monitoreo fijas, distribuidas en la ciudad de León. En este trabajo se hace uso de los datos generados por una de las tres estaciones de monitoreo del SIMEG [15], la cual es llamada CICEG y recibe este nombre dado que se encuentra ubicada en las instalaciones de la Cámara de la Industria del Calzado del Estado de Guanajuato y genera mediciones de los alérgenos contaminantes  $PM_{10}$ ,  $O_3$ ,  $NO_2$ ,  $SO_2$  y  $CO$ . Éstos, junto con el  $Pb$ , entran en la categoría de principales contaminantes del aire [16].

En el presente trabajo, con el propósito de hacer de conocimiento a las personas con padecimientos causadas por alérgenos información relacionada con el nivel actualizado de la calidad del aire de su entorno, se hace uso de una Red Neuronal Backpropagation para predicción de los datos futuros de los alérgenos contaminantes obtenidos por la red de sensores instalada en la estación CICEG. Las redes neuronales son una herramienta que ha demostrado su eficacia a la hora de predicción de datos futuros. Como en [17], donde se hace uso de una Red Neuronal Backpropagation para la predicción a corto plazo de energía eólica, o en [18], donde se logran buenas predicciones en mercado de acciones. El poder predecir los niveles futuros de la calidad del aire, nos ayudará a enviar alertas que aconsejen a las personas con los padecimientos antes mencionados, para que tomen medidas preventivas en caso de un futuro deterioro de la calidad del aire.

El resto de este artículo está organizado de la siguiente manera: en la Sección 2 se presentan conceptos teóricos utilizados en la elaboración de este trabajo. En la Sección 3 se muestra la metodología. En la Sección 4, se discuten los resultados que se obtuvieron. Finalmente, en la Sección 5 se presentan las conclusiones.

## **2. Marco teórico**

### **2.1. Air Quality Index (AQI)**

El AQI es un indicador de la calidad del aire diaria, el cual muestra qué tan limpio está el aire que nos rodea y qué efectos se pueden llegar a generar por dicha calidad del aire. Las mediciones del AQI van de 0 a 500 ppb. Estas mediciones están divididas en cinco categorías (Bueno, Moderado, Insalubre para grupos sensitivos, Insalubre, Muy Insalubre y Peligroso) que se determinan dependiendo del nivel de contaminante que se encuentra en mayor proporción [19]. El AQI se concentra en la medición de cinco de los principales contaminantes del aire:  $PM_x$ ,  $O_3$ ,  $NO_2$ ,  $SO_2$  y  $CO$ . El nivel de la calidad del aire, determinado por el AQI [20], se obtiene utilizando la ecuación 1:

$$I_p = \frac{I_{HI} - I_{LO}}{BP_{HI} - BP_{LO}} (C_p - BP_{LO}) + I_{LO} , \quad (1)$$

donde  $I_p$  es el índice de la calidad del aire,  $C_p$  es la concentración de contaminante observada,  $I_{HI}$  es el punto de quiebre AQI mayor al  $C_p$  observado,  $I_{LO}$  es el punto de quiebre AQI menor al  $C_p$  observado,  $BP_{HI}$  es el punto de quiebre contaminante mayor al  $C_p$  observado y  $BP_{LO}$  es el punto de quiebre contaminante menor al  $C_p$  observado. Los puntos de quiebre AQI se muestran en la Tabla 1, los cuales se sustituyen en la ecuación 1 para conocer el índice de la calidad del aire:

**Tabla 1.** Clasificación de calidad del aire AQI y sus puntos de quiebre (menor y mayor) correspondientes.

Categoría	Punto de quiebre menor	Punto de quiebre mayor	Color Característico de categoría
Bueno	0	50	Verde
Moderado	51	100	Amarillo
Insalubre para grupos sensibles	101	150	Naranja
Insalubre	151	200	Rojo
Muy Insalubre	201	300	Morado
Peligroso	301	500	Marrón

**Tabla 2.** Clasificación de los cinco principales contaminantes, sensados por la estación CICEG, con sus respectivas unidades de medidas.

Contaminante	PM10	O3	SO2	NO2	CO
Unidad de medida	$\mu\text{g}/\text{m}^3$	Ppb.	Ppb.	Ppb.	Ppm.
Bueno	0-54	0-64	0-99	0-198	0-9
Satisfactoria	55-74	65-69	100-109	190-209	9-10
No Satisfactoria	75-174	70-130	110-174	210-315	11-15
Mala	175-274	131-184	175-239	316-420	16-22
Muy Mala	>275	>185	>240	>420	>22

Para los puntos de quiebre de los contaminantes, se utilizó el semáforo de calidad del aire que se publica en el Informe de Estado y Tendencia de la Calidad del Aire Guanajuato 2014 [15]. Los puntos de quiebre para los contaminantes obtenidos por la estación CICEG, se muestran en la Tabla 2.

## 2.2. Red neuronal artificial Backpropagation (RNA-BP)

Rumelhart, Hinton, y Williams, en 1986, introdujeron la red Backpropagation, que es un tipo de descenso de gradiente [21], ya que utiliza el cálculo de los gradientes de una red neuronal para ajustar los pesos [22]. Debido a las ventajas que ofrece esta modalidad de red neuronal artificial, es de las más utilizadas [17].

La función de activación utilizada para la red neuronal fue la sigmoide, también llamada función logística. Esta función de activación tiene un buen rendimiento cuando

los datos para el entrenamiento son positivos, en un rango de valores entre 0 y 1 [22]. La ecuación 2 muestra la función sigmoide:

$$f(x) = \frac{1}{1 + e^{-x}}, \quad (2)$$

para cumplir con el requerimiento de la red, se realizó una normalización de los valores, ubicándolos en un rango entre 0 y 1, a través de la ecuación 3 [23]:

$$y_i = \frac{d - x_{\min}}{x_{\max} - x_{\min}}, \quad (3)$$

donde  $d$ , es el dato a normalizar,  $x_{\max}$  es el valor máximo en la serie de datos y  $x_{\min}$  el mínimo. Se determinó un número total de épocas como criterio de paro, además de un umbral de error definido por un valor epsilon [24]. Este error fue medido de acuerdo a la ecuación 4:

$$\text{Error} = (y_i - f(x_i))^2, \quad (4)$$

donde  $y_i$  es el dato conocido, y  $f(x_i)$  el dato calculado por la red neuronal.

La predicción utilizada en este trabajo mediante la RNA-BP emplea el mecanismo de predicción de series temporales a un paso en el tiempo, ilustrado en la Fig. 1 [25]. Para el conjunto  $n$  de datos de entrada de la RNA-BP, este tipo de predicción permite, una vez entrenada la red, conocer el valor  $n + 1$ , que es desconocido.




Fig. 1. Predicción de series temporales a un paso en el tiempo.

### 3. Metodología

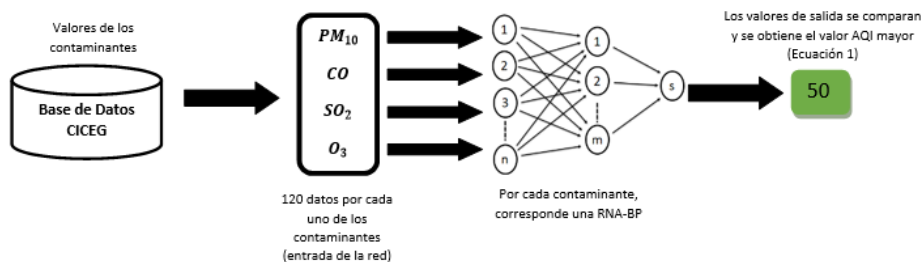
Para el desarrollo de este trabajo, se contó con la colaboración del IEE, que facilitó la obtención de la base de datos generada por la estación CICEG, ubicada en la ciudad de León, Guanajuato. La base de datos cuenta con 96,408 registros, que comprenden un histórico del 1 de enero de 2005 al 31 de diciembre de 2015. Además de la medición de cinco contaminantes ( $PM_{10}$ ,  $O_3$ ,  $NO_2$ ,  $SO_2$  y  $CO$ ), la base de datos cuenta con la información de “Año, Mes, Día, Hora y Temperatura”. En este trabajo se tomaron los datos correspondientes a los contaminantes  $O_3$ ,  $SO_2$ ,  $CO$  y  $PM_{10}$ , debido a que no se tiene disposición de los datos de  $NO_2$  para el intervalo de días seleccionados para las pruebas. La Tabla 3 muestra cómo está constituida la base de datos.

Primeramente, se seleccionaron 120 datos por cada contaminante, que corresponden a cinco días de mediciones, del 21 al 25 de diciembre del 2015 (lunes a viernes). Estos

datos se seleccionaron, ya que en la ciudad de León son los días de más movilización urbana. También, con base a experimentación, la cantidad de datos correspondientes a cinco días generaron buena eficacia en la predicción de la red neuronal; es decir, con un mínimo error obtenido, además de que el tiempo de procesamiento computado es corto. La importancia de estos resultados radica en que se requiere predecir el valor de calidad de aire a una hora en el futuro, para así poder notificar al usuario de las medidas preventivas a tomar. La Fig. 2 representa la metodología empleada para la predicción del valor desconocido por cada contaminante.

**Tabla 3.** Base de datos de niveles para los cinco diferentes contaminantes, generados por la estación CICEG.

Fecha	Hora	O3	SO2	NO2	CO	PM 10	Temperatura
1/1/2005	0	7.02	10.40	151	3	362	14
1/1/2005	1	8.04	17.2	95	2.8	498	16
1/1/2005	2	10	18	101	3.3	490	17
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
31/12/2015	21	9.24	16.1	NA	2.14	82	22
31/12/2015	22	9.01	15.68	NA	2.32	101.05	21.35
31/12/2015	23	8.77	15.06	NA	1.86	90.34	20.98



**Fig. 2.** Metodología utilizada para la predicción de datos de contaminantes de la base de datos generada por la estación CICEG.

Para cada uno de los cuatro contaminantes utilizados de la base de datos de la estación CICEG, se generó una red neuronal artificial Backpropagation (RNA-BP). Cada uno de los valores ingresados como entrada de la red fue normalizado en el rango de 0 a 1 para cumplir con los requerimientos de la RNA-BP, mediante la ecuación 3. La configuración que se utilizó en cada una de las RNA-BP, se muestra en la tabla 4.

**Tabla 4.** Configuración de la red neuronal.

Variable	Épocas	Neuronas Capa Entrada/Oculta/Salida	Criterio de paro	Taza de aprendizaje	Pesos inicializados en rango:
PM10, O3, NO2, SO y CO	50000	85/95/1	0.001	0.03	-2 a 2

Para el proceso de entrenamiento y calibración de los pesos, se tomaron 120 datos (correspondientes a cinco días de monitoreo). De éstos, 85 datos fueron tomados para entrenamiento, correspondiendo cada valor a una neurona de entrada. Para prueba, se utilizaron los 35 datos restantes. La salida de la RNA-BP fue comparada con el valor ya conocido. Este proceso se realizó hasta alcanzar el criterio de paro (0.001), o un número determinado de épocas (50000). Una vez entrenada la red, se ingresó un vector de 85 datos para conocer el dato desconocido a una hora en el futuro generado por la RNA-BP; este dato se comparó con el dato real para conocer la eficacia de la predicción. Se realizaron 35 experimentos para cada una de las RNA-BP (Fig. 2), obteniendo la mediana de los resultados, como parámetro para conocer la eficiencia de la predicción.

La configuración mostrada en la tabla 4 fue seleccionada de acuerdo a los mejores resultados dados por experimentación previa, empleando diferentes parámetros. Una vez obtenido el valor del contaminante introducido en la red neuronal, se hace el proceso inverso a la normalización, haciendo uso de la ecuación 5, la cual se obtiene de despejar la ecuación 3:

$$y = d * (x_{\max} - x_{\min}) + x_{\min} , \tag{5}$$

donde d, es el dato normalizado,  $x_{\max}$  es el valor máximo en la serie de datos normalizados y  $x_{\min}$  el mínimo. Una vez obtenido el dato a su forma original, éste se introduce en el sistema para, mediante la ecuación 1, conocer cuál es el nivel de calidad del aire. Estos niveles de calidad del aire se comparan entre sí para determinar cuál es el que genera un AQI mayor. El mayor determina el mensaje de alerta que es enviado al usuario.


#### 4. Resultados

Una vez entrenada la red, para el proceso de validación, se agregó un vector cuya salida no era conocida por la red. La salida no conocida correspondía a la hora siguiente (1:00 horas) del día siguiente (sábado 26 de diciembre de 2015) a los seleccionados para entrenamiento y prueba. El dato de validación es conocido para verificar la eficacia de la red neuronal. Dado que la salida de la red es un dato que se encuentra normalizado, se realizó el proceso inverso a la ecuación 3, para conocer el dato real y compararlo, resultando la ecuación 5. En la Tabla 5 se aprecian las medianas de los resultados que arrojaron los 35 experimentos realizados en la predicción de los datos seleccionados de la estación CICEG con la red neuronal.

**Tabla 5.** Resultado de los 35 experimentos realizados con la red neuronal.

	PM	CO	SO2	O3
Real	54.78	1.49	10.41	8.58
Salida de la red	52.45	1.56	10.64	10.77

Los valores de los contaminantes fueron substituidos en la Ecuación 1 AQI, para conocer cuál era el que determinaba el nivel de calidad del aire. En la Tabla 6 se aprecian los resultados.



**Fig. 3.** Comportamiento del error cuadrático medio en el proceso de entrenamiento de la red para los cuatro contaminantes.

**Tabla 6.** Valor AQI, para los resultados de los experimentos de la red neuronal mostrados en la tabla 5.

	PM10	CO	SO2	O3
AQI	48.56	8.7	5.37	40.9
Categoría	Bueno	Bueno	Bueno	Bueno

El comportamiento del error observado en el proceso de entrenamiento de la red, para cada uno de los contaminantes anteriores (Tabla 6), se observa en la Fig. 3.


En cada uno de los experimentos realizados se obtuvo el criterio de alcanzar un error igual a 0.001, en la etapa de entrenamiento de la RNA-BP. La mediana de los errores finales (tras 35 experimentos), para cada contaminante, se aprecia en la Tabla 7.

**Tabla 7.** Resultados de las medianas del valor de los errores de los 35 experimentos realizados.

	PM10	CO	SO2	O3
AQI	0.000999912	0.000999902	0.000999751	0.000999991

Como se observa en la Tabla 6, el índice AQI que mayor valor mostró fue el contaminante PM10. Debido a que el índice AQI se toma en base al contaminante que se encuentra en mayor proporción en el ambiente, el AQI para la hora predicha por la red sería 48.56, que equivale a la categoría de calidad del aire “Bueno”. La Figura 4 muestra una recomendación para esta categoría.





**Fig. 4.** Ejemplo de mensaje enviado al usuario, al conocer el nivel de calidad del aire predicho por la red.

## 5. Conclusiones y trabajo futuro

La técnica utilizada para este trabajo, su arquitectura y configuración, y los datos obtenidos con los que se realizaron los experimentos, demostraron una vez más, el buen funcionamiento de las redes neuronales Backpropagation al momento de realizar predicciones. Como se puede observar en la tabla 5, los valores obtenidos en la salida de la red neuronal son muy cercanos a los valores reales (no conocidos por la red neuronal) de los contaminantes medidos por la estación CICEG. Debido a que los resultados permiten tener confianza en las predicciones de la red neuronal y así, poder mantener al tanto a las personas del nivel de calidad del aire que pueden experimentar en el futuro cercano, manteniéndolas informadas para tomar acciones preventivas y no tener que sufrir reacciones adversas en su salud, se concluye que para los datos con los que se trabajó, la arquitectura de la red neuronal genera buenos resultados.

Es importante mencionar que los valores de las mediciones de contaminantes obtenidos por la estación CICEG varían mucho de una hora a otra, esto debido a factores como el nivel de tráfico, los horarios de trabajo en fábricas cercanas a la estación, condición climática, entre otros. Como este puede variar (para bien o para mal) de una hora a otra, el sistema es capaz de enviar alertas con base a las observaciones de la estación. Así, cuando la red neuronal falle en alguna predicción, se mantiene al mínimo el nivel de riesgos en la salud de las personas con las enfermedades ya mencionadas. Se espera con esto el incentivar a las personas que sufren de padecimientos del tipo respiratorio, al estar más al tanto de la calidad del aire del entorno en el que se desarrollan. Manteniéndose informados, pueden decidir en qué hora del día es mejor para su salud realizar actividades al aire libre, por citar un ejemplo. Basándonos en la opinión de expertos, el problema de la contaminación es algo que continuará existiendo y que seguirá siendo un foco de atención para la sociedad, y al mantenerse informado se puede crear conciencia para cuidar más el medio ambiente.

Como trabajo futuro se propone realizar el procesamiento de las bases de datos generadas por las demás estaciones ubicadas en la ciudad de León y así poder tener un panorama general del nivel de calidad del aire en la ciudad. Además, se propone buscar más información con expertos en el área de las alergias, para que las recomendaciones emitidas sean más precisas y se vayan adaptando conforme se vayan dando nuevos descubrimientos en el problema. También, se propone utilizar otras herramientas de predicción como el ajuste de datos por mínimos cuadrados, y realizar experimentos para ver cual ofrece mejor desempeño en la predicción y/o coste computacional u otras características que ayuden a agilizar al sistema de predicción y así emitir mejores alertas y con mayor rapidez. Además, emplear sensores que nos permitan conocer la calidad

del aire en interiores, ya que dependiendo de los contaminantes que existen en interiores se puede inclusive, llegar a generar asma estacional.

**Agradecimientos.** Se agradece el apoyo económico brindado al Consejo Nacional de Ciencia y Tecnología (CONACYT), para la realización de este trabajo. También, agradecimientos especiales al Dr. M. Ornelas-Rodríguez y a los ingenieros D. Duarte-Carrera y A. Godínez-Bautista, por sus apreciados comentarios.

## Referencias

1. Yang, X., Du, J., Liu, S., Li, R., Liu, H.: Air pollution source estimation profiling via mobile sensor networks. *Int. Conf. Comput. Inf. Telecommun. Syst.* (2016)
2. Baralis, E., Cerquitelli, T., Chiusano, S., Garza, P., Kavosifaris, M. R.: Analyzing air pollution on the urban environment. pp. 1464–1469 (2016)
3. Bose, B.: Global Warming: Energy, Environmental Pollution, and the Impact of Power Electronics. *IEEE Ind. Electron. Mag.*, Vol. 4, No. 1, pp. 6–17 (2010)
4. Guo, D., Zhang, Y., He, L., Zhai, K., Tan, H.: Chebyshev-polynomial neuronet, WASD algorithm and world population prediction from past 10000-year rough data. In: *Proc. 27th Chinese Control Decis. Conf. CCDC*, pp. 1702–1707 (2015)
5. Melorose, J., Perroy, R., Careas, S.: World population prospects. United Nations, Vol. 1, No. 6042, pp. 587–92 (2015)
6. C. de N. ONU.: Proyectan aumento en población urbana para 2050. United Nations, Disponible en: <http://www.un.org/spanish/News/story.asp?NewsID=11754#>. WNGX\_Ts1-Um (2008)
7. Garrido-Lestache, J. S., Rodríguez-García, V.: Las enfermedades alérgicas (2012)
8. Onatra, W., Vargas, S., Paez, E., Rojas, D., Lopez, A.: Correlación entre la enfermedad respiratoria aguda ( era ) en mujeres embarazadas y la calidad del aire. *Rev. U.D.C.A Act. Div. Cient.*, Vol. 12, No. 2, pp. 27–37 (2009)
9. Saad, S. M., Saad, A. R. M., Kamarudin, A. M. Y., Zakaria, A., Shakaff, A. Y. M.: Indoor air quality monitoring system using wireless sensor network (WSN) with web interface. In: *Int. Conf. Electr. Electron. Syst. Eng.*, pp. 60–64 (2013)
10. Alcalá-padilla, G.: Prevalencia de sensibilización a alérgenos en niños escolares con asma que viven en la zona metropolitana de Guadalajara. *Rev. Alerg. Mex.*, Vol. 63, No. 2, pp. 135–142 (2016)
11. de la Luz Cid, M.: Estudio aerobiológico de pólenes anemófilos en la ciudad de Toluca, México. *Rev. Alerg. Mex.* Vol. 62m No. 1, pp. 8–14 (2015)
12. Baena-Cagnani, C. E.: Actualización de rinitis alérgica y su impacto en el asma (ARIA 2008). La perspectiva latinoamericana. *Rev. Alerg. Mex.*, Vol. 56, No. 2, pp. 56–63 (2009)
13. Sánchez-González, A.: ARIA México 2014 Adaptación de la Guía de Práctica Clínica ARIA 2010 para México. Metodología ADAPTE ARIA Mexico 2014 Adaptation of the Clinical Practice Guide ARIA 2010 for Mexico. Vol. 61, pp. 3–116 (2014)
14. Pieri, T., Michaelides, M. P.: Air Pollution Monitoring in Lemesos using a Wireless Sensor Network. pp. 18–20 (2016)
15. Gobierno del Estado de Guanajuato e Instituto de Ecología del Estado.: Informe

- de Estado y Tendencia de la Calidad del Aire Guanajuato 2014. Guanajuato (2014)
16. Bagiński, Z.: Traffic air quality index. *Sci. Total Environ.*, Vol. 505, pp. 606–614 (2015)
  17. Zhang, G.: Prediction of Short-Term Wind Power in Wind Power Plant based on BP-ANN. pp. 75–79 (2016)
  18. Guanqun, D., Fataliyev, K., Wang, L.: One-step and multi-step ahead stock prediction using backpropagation neural networks. In: ICICS 2013 - Conf. Guid. 9th Int. Conf. Information, Commun. Signal Process., No. weights 2, pp. 2–6 (2013)
  19. Kyrkilis, G., Chaloulakou, A., Kassomenos, P. A.: Development of an aggregate Air Quality Index for an urban Mediterranean agglomeration: Relation to potential health effects. *Sci. Direct*, Vol. 33, No. 2, pp. 670–676 (2007)
  20. García, B.: Los Índices de Calidad del Aire: Alcances y Limitaciones. En: *Concienc. Tecnológica*, pp. 74–76 (2011)
  21. Heaton, J.: Artificial Intelligence for Humans. *Deep Learning and Neural Networks*, Vol. 3 (2015)
  22. Heaton, J.: *Introduction to the Math of Neural Networks* (2012)
  23. Heaton, J.: *Artificial Intelligence for Humans. Volume 1: Fundamental Algorithms*. Heaton Research. Incorporated (2013)
  24. Kandel, A.: *Introduction to pattern recognition: statistical, structural, neural, and fuzzy logic approaches*, Illustrate. Vol. 32, World Scientific (1999)
  25. Isasi-Viñeala, P., Galván-Leon, I. M.: *Redes de neuronas artificiales: un enfoque práctico*. Pearson Education (2004)