



Red Neuronal Artificial para la Clasificación y Predicción de la Calidad del Aire

Artificial Neural Network for the Classification and Prediction of Air Quality

Sandra Patricia Bombela Jiménez, Carlos Lino Ramírez, David Asael Gutierrez Hernández , Victor Manuel Zamudio Rodríguez , Miguel Ángel Casillas Araiza

División de Estudios de Posgrado e Investigación/Tecnológico Nacional de México/I.T. León, Av. Tecnológico S/N Fracc. Industrial Julián de Obregón, León Guanajuato, México, C.P. 37290

*Correo-e: sandy.bombela@gmail.com

PALABRAS CLAVE: RESUMEN

Extrapolación, Red Neuronal Artificial, contaminación, predicción.

Se entiende por contaminación atmosférica a la presencia en la atmósfera de sustancias en una cantidad que implique molestias o riesgo para la salud de las personas y de los demás seres vivos, vienen de cualquier naturaleza, así como que puedan atacar a distintos materiales, reducir la visibilidad o producir olores desagradables. Las emisiones a la atmósfera relacionadas con el cambio climático pueden agravar los efectos de la contaminación del aire sobre la salud de los ciudadanos, no solo indirectamente por el impacto en los fenómenos meteorológicos, sino, de manera inmediata, por los efectos directos de los contaminantes para la salud. En este artículo se propone la aplicación de una red neuronal con un entrenamiento supervisado de tipo Backpropagation para hacer predicciones una hora después acerca del estado de la calidad del aire, utilizando métodos de estimación para completar los registros faltantes de las bases de datos utilizadas. El estudio está basado en cuatro años obtenidos de la estación CICEG, una de las tres estaciones que se encuentran en la ciudad de León, Gto. Se consideran cinco (NO_2 , PM_{10} , SO_2 , O_3 , CO) además del mes, el día y la hora en que se registró el contaminante. Los resultados muestran una aceptable precisión del modelo utilizado para la predicción de la calidad del aire.

KEYWORDS: ABSTRACT

Extrapolation, Artificial Neural Network, pollution, prediction.

Air pollution is the presence in the atmosphere of substances in an amount that involves discomfort or risk to the health of people and other living beings. They are being produced in different ways, and they can attack different materials, reduce visibility or produce unpleasant odors. Polluted emissions to the atmosphere (which is strongly related to climate change) can aggravate the effects on the health of population, not only indirectly (by the impact on weather phenomena), but immediately, due the direct effects of pollutants for health. In this paper we propose the application of a back propagation neural network to make predictions (one hour later) about the air quality, using estimation methods to complete the missing records of the databases used. This study is based on a four years database obtained from the CICEG atmosphere station, one of the three stations that are located in the city of León, Guanajuato Mexico. Five pollutants are considered as part of the parameters of the model (NO_2 , PM_{10} , SO_2 , O_3 , CO) in addition to the month, the day and the time when the contaminant were registered. The results show an acceptable accuracy of the model used for the prediction of air quality.

Recibido: 6 de Agosto de 2018 • Aceptado: 6 de mayo de 2019 Publicado en línea: 28 de febrero 2019

1 INTRODUCCIÓN

Con la llegada de la Revolución Industrial (Inglaterra, entre 1760 y 1800), se diseñaron procesos de producción utilizando energía y maquinaria para fabricar producto que no eran directamente proporcionados por la naturaleza. De esta manera nació la gran industria actual [1]. El crecimiento industrial ha traído avances a nuestra sociedad, pero a su vez aumenta la contaminación en el aire en todo el mundo, afectando nuestra salud, aumentando el número de muertes por enfermedades cardiovasculares y respiratorias en personas mayores [2].

Cuatro ciudades guanajuatenses (León, Salamanca, Irapuato y Silao, junto con Ciudad de México, Monterrey, Toluca y Puebla), tienen serios problemas de contaminación en el aire. Greenpeace México publicó que son las 8 ciudades más contaminadas del País, y 4 de ellos están en Guanajuato[3]. Por lo anterior, las organizaciones medioambientales y las instituciones gubernamentales están cada vez más convencidas de la importancia del monitoreo de los contaminantes ambientales [4].

En este artículo se propone un esquema de monitorización de contaminantes ambientales en tiempo real para la predicción de la calidad del aire

utilizando una red neuronal artificial (RNA) y la extrapolación para el pre procesamiento de los datos.

El artículo está organizado de la siguiente manera: en la Sección II se presentan los antecedentes de trabajos realizados utilizando metodologías similares. En la sección III se presentan los conceptos teóricos utilizados para la elaboración del trabajo. En la Sección IV se muestra la metodología utilizada. En la Sección V se muestran y se discuten los resultados obtenidos y por último en la sección VI se muestran las conclusiones y el posible trabajo a futuro.

2 ANTECEDENTES

En el trabajo realizado por Alver et al. [5] se presenta una arquitectura de detección móvil capaz de monitorear diferentes contaminantes utilizando sensores de gama baja. Aunque la propuesta de solución se puede implementar en todas partes, se vuelve especialmente significativa en las ciudades atestadas donde los valores de contaminación a menudo son altos.

La arquitectura propuesta se muestra en la figura 1, utiliza un sensor móvil para monitorear contaminantes ambientales, un dispositivo basado en Android para mostrar el estado de la contaminación en tiempo real. Los sensores móviles se pueden instalar en bicicletas o en el transporte público para monitorear toda la ciudad. Toda la información recopilada se almacena en un servidor central para el procesamiento de datos, generando información detallada después. La aplicación móvil permite iniciar o detener un seguimiento y cargar datos en el servidor aplicando técnicas de interpolación para crear mapas detallados de contaminación.

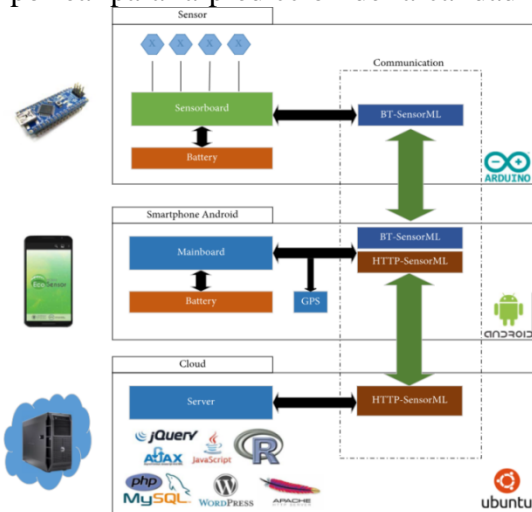


Fig. 1 Descripción general de la arquitectura de detección móvil propuesta que incluye los principales componentes de hardware y las tecnologías utilizadas. Tomado de [5].

En su tesis doctoral Cortina Januchs [6], propone un modelo de predicción de concentración de los contaminantes más críticos SO_2 y PM_{10} para cada

caseta de monitorización de la Red de Monitorización Atmosférica de Salamanca, Gto., el modelo propuesto utiliza una red neuronal y algoritmos de agrupamiento (K-means y FCM). Los algoritmos de agrupamiento son utilizados para encontrar correlación existente entre los contaminantes atmosféricos y las variables meteorológicas, para aportar la información a la red neuronal artificial y hacer la predicción.

En el trabajo realizado por Cerna [7], se utiliza una red neuronal artificial, con un algoritmo de Backpropagation para la predicción de datos de contaminación. Utiliza datos obtenidos de la estación CICEG de la ciudad de León, Gto., haciendo un filtrado descartando los datos NAN (Not a Number). Con ello se pretendía informar a las personas con rinitis alérgica y asma. La predicción la realiza sobre cada uno de los contaminantes una hora siguiente del día siguiente, finalmente se clasifica la calidad del aire de acuerdo al AQI, que es un estándar para la notificación de la calidad del aire a diario. Indica el grado de pureza o contaminación atmosférica y los efectos para la salud conexos que le podrían preocupar.

3 MARCO TEÓRICO

El Sistema Estatal de Información de Calidad del Aire

El Sistema Estatal de Información de Calidad del Aire del estado de Guanajuato es un servicio que permite a los ciudadanos, empresas, organismos e instituciones, acceder a la información sobre el medio ambiente y la calidad del aire respecto a contaminantes [8]. Esta información es generada por el Instituto de Ecología del Estado a través de programas y regulaciones, así como de instrumentos estratégicos de gestión, buscando mejorar la difusión del conocimiento para la mejora de la calidad del aire en el Estado de Guanajuato y el bienestar de sus ciudadanos. En la tabla I se muestra una clasificación y los límites de los cinco principales contaminantes en la ciudad de León.

Tabla 1 Clasificación de los cinco principales contaminantes (dioxido de nitrógeno, partículas menores a

10 $\mu\text{g}/\text{m}^3$, dioxido de azufre, ozono, monoxido de carbono) por el SEICA, sensados por las tres estaciones ubicadas en la ciudad de León, con sus respectivas unidades de medida

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

Extrapolación Polinomial

La extrapolación se aplica cuando se estima un valor de $f(x)$ fuera del rango de los datos conocidos, x_0, x_1, \dots, x_n . Cuando se realiza una extrapolación, el error de extrapolar puede ser muy grande ya que la búsqueda se extiende más allá de la región conocida. En la figura 2, se representa de manera gráfica tanto la interpolación como la extrapolación de funciones [9]; la línea roja es la curva real y la azul es la extrapolación polinomial, la extrapolación se basa en el ajuste de una parábola a través de los tres primeros puntos conocidos.

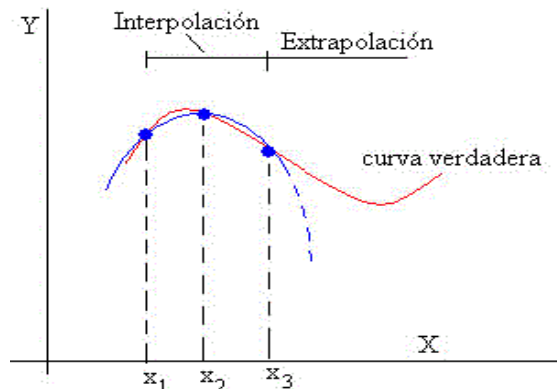


Fig. 2 Ilustración de una posible divergencia de predicción extrapolada. Tomada de [10].

Red Neuronal Artificial

Las Redes Neuronales Artificiales (RNA) son modelos matemáticos-computacionales que poseen una elevada capacidad de generalización y de tratamiento de problemas tanto lineales como no lineales, no requiere un conocimiento exhaustivo de

las variables en estudio. Las RNA tratan de emular el sistema nervioso, de forma que son capaces de reproducir algunas de las principales tareas que desarrolla el cerebro humano, al reflejar las características fundamentales del comportamiento del mismo [6].

El perceptrón multicapa (MLP-MultiLayer Perceptron, por sus siglas en inglés) que es utilizado en esta investigación, incluye en su arquitectura una o varias capas intermedias, llamadas capas ocultas como se muestra en la Fig. 3. Esta arquitectura suele entrenarse mediante el algoritmo de retropropagación de errores o BackPropagation (BP- por sus siglas en inglés) [6].

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 [10]. La ecuación (1) muestra la función sigmoide[11]:

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

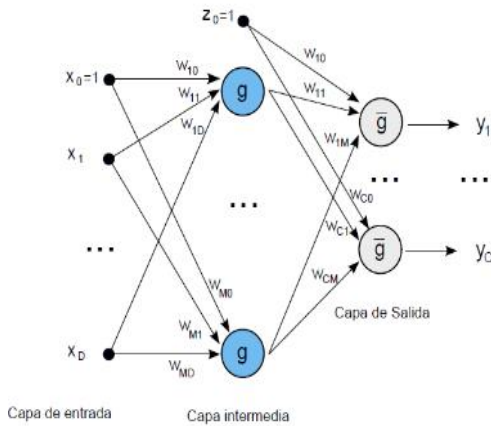


Fig. 3 Arquitectura de un perceptrón multicapa con una

4 METODOLOGÍA

En el diagrama 1 se muestran los pasos a seguir para llevar a cabo la presente investigación, se explicará detalladamente que fue lo que se realizó en cada uno de los pasos.

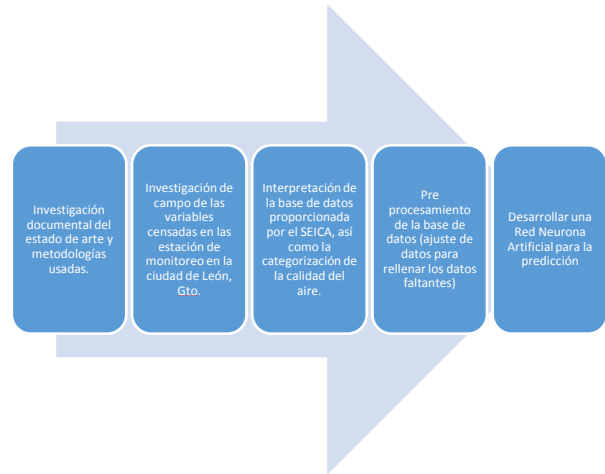


Diagrama 1 Metodología

Para el desarrollo de este trabajo, se utilizaron los datos proporcionados por el Sistema Estatal de Información de Calidad del Aire (SEICA), la base de datos que se utilizó fue generada por la (1) ón CICEG (una de las tres estaciones ubicadas en la ciudad de León, Guanajuato). La base de datos cuenta con 35,040 registros, que comprenden un histórico del 1 de enero del 2014 al 31 de diciembre del 2017. Los registros son de cinco contaminantes, dióxido de nitrógeno, partículas menores a $10 \mu g/m^3$, dióxido de azufre, ozono y monóxido de carbono ($NO_2, PM_{10}, SO_2, O_3, CO$) además contiene el mes, día y hora (de la hora 0 a las 23 horas), en que se registró el contaminante.

La base de datos fue etiquetada de acuerdo al semáforo de calidad del aire del SEICA que se divide en cinco categorías (Buena, Satisfactoria, No satisfactoria, Mala y Muy mala), para cada una de las instancias se verifica a que categoría pertenece cada uno de los cinco contaminantes obteniendo así cinco posibles categorías, después la categoría asignada a la instancia la peor de estas cinco. Los límites para definir a que categoría pertenece cada contaminante se encuentran especificados en la tabla

2. En los años 2014 al 2017 no existieron registros que pertenecían a la categoría “Mala” y “Muy Mala”.

Tabla 2 Ejemplo de base de datos antes de ser transformada

Instancia	Atr1	Atr2	Atr3	Etiqueta
1	A1	B1	C1	E1
2	A2	B2	C2	E2
3	A3	B3	C3	E3
4	A4	B4	C4	E4

Debido a que la base de datos no tiene registrado todos los contaminantes en todos los días y en todas las horas, sino que hay datos que por motivos externos no fueron registrados (porque el sensor dejó de funcionar o porque hubo mantenimiento), el informe de ese contaminante se llena con un dato NaN (Not a Number). Para poder trabajar con todos los registros de la base de datos, fue necesario asignar valores a los campos NaN, para aproximar estos valores se utilizó una extrapolación polinomial de grado 3. La fig. 4 muestra un ejemplo de cómo los datos son extrapolados, con la variable PM10 en el año 2015, donde el eje “x” es el tiempo (las 8760 horas) el eje “y” los valores de la variable a extrapolar, los puntos azules son los datos que si fueron registrados correctamente por los sensores, y la línea naranja señala como los datos faltantes fueron extrapolados, la extrapolación se realizó por año y por variable a excepción de la variable NO_2 en el año 2015-2016.




Fig. 4 Extrapolación PM10 2015.

Debido a que no se contaba con suficiente información al final del año 2015 y a principios del año 2016 en la variable NO_2 , se unieron ambos años y se extrapoló como se muestra en fig. 5.

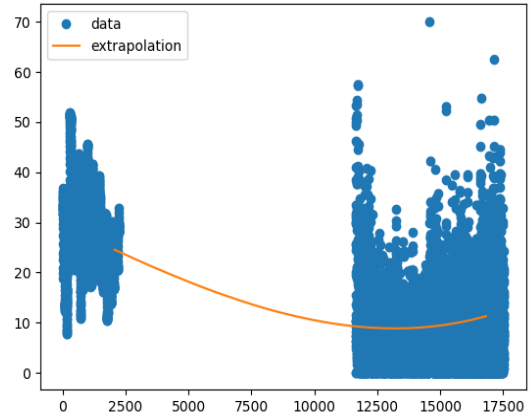


Fig. 5 Extrapolación de NO_2 , de los años 2015 y 2016

Después de haber extrapolado los datos faltantes, se aplica una operación de retraso para transformar la base de datos [12]. Es decir, para predecir la calidad del aire de la próxima hora se tienen que incluir en el procesamiento no solo los datos actuales sino también datos pasados, los últimos dos o tres registros pasados como se muestra en la tabla 3 donde la transformación de la base de datos para predecir la etiqueta (calidad del aire) de la instancia 4, se utilizan los atributos de las instancias 1, 2 y 3 como se muestra en la tabla 2.

Tabla 3 Ejemplo de transformación de la base de datos.

Atr1	Atr2	Atr3	Atr4	Atr5	Atr6	Atr7	Atr8	Atr9	Etiqueta
A1	B1	C1	A2	B2	C2	A3	B3	C3	E4

Una vez teniendo los registros completos de la base de datos se utilizó el modelo de perceptrón multicapa (MLP) que viene implementado en la herramienta weka como se muestra en la fig. 6 para experimentar con las bases de datos y así obtener resultados sobre la predicción de la calidad del aire. El modelo MLP que implementa weka ejecuta ya

Variable	Neuronas en capa de entrada	Neuronas en capa oculta	Neuronas en capa de salida	Taza de aprendizaje	K-fold
$NO_2, PM_{10}, SO_2, O_3, CO$	15	10	5	0.03	10

ciertas configuraciones como lo es la normalización de datos, la validación cruzada estratificada, etc. El error reportado por weka es la raíz del error medio cuadrado [13], calculado con la ecuación




Fig. 6 Arquitectura de la red neuronal utilizada

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{\theta} - \theta)^2} \quad (2)$$

La base de datos fue dividida en cuatro bases de datos (una por cada año) y se entrenaron cuatro modelos de MLP, obteniendo así resultados por cada uno de los años.

5 EXPERIMENTACIÓN Y RESULTADOS

El modelo de perceptrón multicapa se ejecuta con la configuración de la tabla 4. Utilizando 15 neuronas en la capa de entrada, 10 en la capa oculta y 4 en la capa de salida, con una taza de aprendizaje de 0.03 y con 10 K-folds

Tabla 4 Configuración del Perceptrón Multicapa

La tabla 5 muestra los resultados de precisión por la base de datos de cada año. En el año 2015 se obtuvo mejor porcentaje de correcta clasificación con un error cuadrático medio del 0.1144.

Tabla 5 Resultados de la clasificación de MLP

Año	Instancias	Correcta clasificación	Incorrecta clasificación	Raíz del error cuadrado medio
2014	8757	93.11%	6.88%	0.1488
2015	8757	95.98%	4.01%	0.1144
2016	8781	94.20%	5.79%	0.1406
2017	8757	91.46%	8.53%	0.1654

Las tablas 4-7 representan las matrices de confusión de las respectivas bases de datos, resultantes de la experimentación con el software weka.

Donde a=Buena, b=Satisfactoria, c=No satisfactoria, d=Mala y e=Muy mala.

En las tablas las columnas nos muestran lo que predice el modelo de red neuronal utilizado y los renglones son las clases reales a las que pertenece cada instancia. En la tabla 6 se puede observar como hay 603 datos mal clasificados, 292 de los datos que pertenecían a la instancia “a” fueron clasificados como “b” y otros 15 como “c”, 171 de los datos que pertenecían a “b” fueron clasificados como “a” y otros 62 como “c” y 63 de los datos que pertenecían a “c” fueron clasificados como “b”.

Tabla 6 Matriz de confusión CICEG 2014

a	b	c	d	e	
213	292	15	0	0	a
171	5632	62	0	0	b
0	63	2309	0	0	c

0	0	0	0	0	d
0	0	0	0	0	e

1900	215	55	0	0	a
234	3512	147	0	0	b
0	96	2598	0	0	c
0	0	0	0	0	d
0	0	0	0	0	e

En la tabla 7 se puede observar como hay 349 datos mal clasificados, en la tabla 8 hay 503 datos mal clasificados y en la tabla 9 hay 747 datos mal clasificados. La mejor matriz de confusión fue la del año 2015 ya que menos errores tuve al momento de clasificar.

Tabla 7 Matriz de confusión CICEG 2015

a	b	c	d	e	
259	120	5	0	0	a
67	5219	83	0	0	b
21	56	2927	0	0	c
0	0	0	0	0	d
0	0	0	0	0	e

Para todos los casos se obtuvo como resultado más de un 90% de precisión en la predicción de la calidad del aire. Se puede observar que en los años 2015 y 2016 el porcentaje de precisión es mayor, esto podría deberse a que en estos años hay la mayor cantidad de datos faltantes para la variable NO_2 , estos datos faltantes que fueron extrapolados pudieron haber sesgado el procesamiento de la red neuronal.

En las matrices de confusión se puede observar que la mayoría de las instancias pertenecen a las categorías de “Satisfactoria” y “No satisfactoria”, en ninguno de los casos clasificó entre las categorías “Mala” y “Muy mala”.

Tabla 8 Matriz de confusión CICEG 2016

a	b	c	d	e	
1329	128	67	0	0	a
156	3374	83	0	0	b
6	69	3569	0	0	c
0	0	0	0	0	d
0	0	0	0	0	e

6 CONCLUSIONES Y TRABAJOS FUTUROS

El resultado de este trabajo de investigación nos lleva a concluir que el modelo de red neuronal artificial aplicado, permite la predicción de niveles de calidad de contaminación atmosférica en León, Gto. Contar con un modelo de predicción de calidad del aire puede servir de apoyo a las autoridades correspondientes para tomar decisiones preventivas e informar a la población para que esta tome precauciones.

Tabla 9 Matriz de confusión CICEG 2017

a	b	c	d	e	
----------	----------	----------	----------	----------	--

Los valores obtenidos por el SEICA varían mucho de una hora a otra debido a factores como el tráfico, si es día feriado o no, si son vacaciones, si es horario en que las fabricas trabajan, si es horario escolar, etc., su comportamiento no es una distribución normal y el llenado de los datos no puede realizarse con el promedio de los mismos, por eso se buscó otro método de estimación para completar los datos faltantes. El método de estimación utilizado fue la extrapolación polinomial de grado 3, ya que si se hacía de un grado mayor el error del ajuste se disparaba y si se hacía de menos grados no se ajustaba los suficiente a la función original (como se comportaban los datos).

Como trabajo futuro se propone realizar un estudio más profundo enfocado a métodos de estimación para completar los registros con campos NaN, como técnicas como interpolación y extrapolación, técnicas de regresiones, series de tiempo, etc. También realizar experimentación de las otras dos estaciones ubicadas en la ciudad de León, Gto., para tener información general de la contaminación atmosférica en toda la ciudad. Además de experimentar con otros modelos de predicción como árboles de decisión, máquinas de soporte vectorial u otros modelos de redes neuronales para hacer una comparativa y mostrar cual ofrece mejor predicción. También se realizará experimentación sobre datos que están siendo

recolectados con estación que fue instalada y configurada en las instalaciones del Instituto Tecnológico de León.

Estudios de Posgrado del Instituto Tecnológico de León por brindar las facilidades para cursar la Maestría en Ciencias de la Computación.

AGRADECIMIENTOS

Agradezco al Consejo de Ciencia y Tecnología (CONACYT) por el apoyo económico brindado para la elaboración de este trabajo y a la División de

REFERENCIAS

- [1] Salvador, G. L. Contaminación Industrial. *Periódico el Financiero*, 2016. [Acceso online; accesado el 22- Noviembre-2017] <http://www.elfinanciero.com.mx/opinion/contaminacion-industrial.html>.
- [2] Anthony, S., Godden, D., MacNee, W., and Donaldson, K. Particulate air pollution and acute health effects. *The lancet*, 345(8943):176, 178, 1995.
- [3] Alfonso, J. L. Cuatro ciudades en Guanajuato que se asfixian. *Periódico am*, 2018. [Acceso online; el 22-Marzo-2018] <https://www.am.com.mx/2018/02/22/local/cuatro-ciudades-de-guanajuato-se-asfixian-vives-en-una-de-ellas-437943>.
- [4] Mage, D., Ozolins, G., Peterson, P., Webster, A., Orthofer, R., Vandeweerd, V., and Gwynne, M. Urban air pollution in megacities of the world. *Atmospheric Environment*, 30(5):681, 686, 1996.
- [5] Oscar Alvear, Willian Zamora, Carlos Calafate, Juan Carlos Cano, and Pietro Manzoni. An architecture oering mobile pollution sensing with high spatial resolution. *Journal of Sensors*, 2016, 2016.
- [6] Januchs, M. G. Aplicación de técnicas de Inteligencia Artificial a la predicción de contaminantes atmosféricos. En M. G. Januchs, *Aplicación de técnicas de Inteligencia Artificial a la predicción de contaminantes atmosféricos* (pág. 259). Universidad Politécnica de Madrid: Escuela
- [14] Gwynne. Urban air pollution in megacities of the world. *Atmospheric Environment*, 30(5):681, 686, 1996.
- Técnica Superior de Ingenieros y Telecomunicaciones (2012).
- [7] Cerna-Vázquez, D., Lino-Ramírez, C., Díaz-Ramírez, A., Mosiño, J. F., Casillas-Araiza, M. A., Baltazar-Flores, R., & Mendez-Zamora, G. Red neuronal Backpropagation para la predicción de datos de contaminación y prevención de ataques a personas con padecimientos de rinitis alérgica y asma
- [8] Estado, I. d. (19 de mayo de 2018). Sistema Estatal de Información de Calidad del Aire. Obtenido de SEICA: <https://seica.guanajuato.gob.mx/>
- [9] Chávez, M. A. Interpolación y Extrapolación. *Licenciatura en Electrónica y Computación: Métodos Numéricos CIICAp*, 7 (2017).
- [10] Heaton, J.: *Introduction to the Math of Neural Networks* (2012)
- [11] Varela, I. C.. Impacto de la contaminación en la salud del ser humano análisis del reglamento de la ley general del equilibrio ecológico y la protección al ambiente en materia de prevención y control de la contaminación atmosférica. *Delos: desarrollo local sostenible*, (2012), 5(15), 20.
- [12] Ballester, F. Contaminación atmosférica, cambio climático y salud. *Revista Española de Salud Pública* (2005). 79(2), 159-175.
- [13] David Mage, Guntis Ozolins, Peter Peterson, Anthony Webster, Rudi Orthofer, Veerle Vandeweerd, and Michael

Acercas de los autores



Sandra Patricia Bombela Jiménez, obtuvo el título de Ingeniero en Telemática por la Universidad Politécnica de Juventino Rosas en el 2018. Actualmente cursa la Maestría en

Ciencias de la Computación en su segundo año en la División de Estudios de Posgrado e Investigación en el Instituto Tecnológico de León. Ha trabajado con algoritmos genéticos aplicados a la optimización en la clasificación de arritmias cardiacas. Recientemente se encuentra trabajando con métodos de ajustes de datos.



Carlos Lino Ramírez, profesor Investigador de la División de Estudios de Posgrado e Investigación (DEPI) del Tecnológico Nacional de México / I. T. de León. Doctorado en Arquitectura y Tecnología de los

Sistemas Informáticos por la Universidad de Valencia, España (2012). Maestro en Ciencias en Ciencias Computacionales por el Instituto Tecnológico de León (1999). Ingeniero en Sistemas Computacionales por el Instituto Tecnológico de León (1996). Ha tenido varios cargos administrativos en el Instituto Tecnológico de León, como: jefe de la División de Estudios de Posgrado e



David Asael Gutiérrez Hernández, ha tenido varios cargos administrativos en el Instituto Tecnológico de León, como: jefe de la División de Estudios de Posgrado e Investigación y profesor Investigador de la División de Estudios de Posgrado e

Investigación (DEPI) del Tecnológico Nacional de México / I. T. de León. Ingeniero en Comunicaciones y Electrónica por la Universidad de Guanajuato, Maestro en Ciencias (óptica) por

Investigación (2015-2017), subdirector académico del (2006-2007), jefe del departamento académico de Sistemas y Computación (2004-2006), entre otros. Ha publicado sus trabajos de investigación en diversos congresos internacionales en España, Italia, Alemania y México. Sus áreas de investigación son Inteligencia de Ambiente, Algoritmos de Encaminamiento y Redes de Sensores Inalámbricas.



Víctor Manuel Zamudio Rodríguez, profesor Investigador de la División de Estudios de Posgrado e Investigación (DEPI) del Tecnológico Nacional de México / I. T. de León. Doctorado en Ciencias de la Computación por la

Universidad de Essex, Reino Unido. Maestro en Ciencias de la Computación por el Instituto Tecnológico de Monterrey, México. Licenciado en Física y Matemáticas por la Universidad Autónoma de San Luis Potosí, México. Sus áreas de interés es la aplicación de métodos de Inteligencia Artificial como la inteligencia ambiental, robótica, informática móvil, educación, salud, realidad mixta, etc. También está interesado en la innovación y el emprendimiento, el aprendizaje basado en proyectos, el prototipado de ciencia ficción y las artes más la tecnología.

el Centro de Investigaciones en Óptica, Doctor en Física por la Universidad Autónoma de Sinaloa.

Investigador Nacional Nivel 1 y Jefe de la División de Estudios de Posgrado e Investigación del Instituto Tecnológico de León. Investigador en el área de metrología óptica con trabajos realizados referentes a pruebas ópticas no destructivas para caracterización de propiedades mecánicas de materiales, procesamiento digital de imágenes y en optoelectrónica aplicada al monitoreo no invasivo de enfermedades crónico-degenerativas y neurodegenerativas. Ha sido

ganador del premio de innovación tecnológica Guanajuato 2010 y 2012, así como del premio Nacional de la Cámara Nacional de la Industria Farmacéutica 2013 por sus trabajos de optoelectrónica aplicada a la ingeniería biomédica.



Miguel Ángel Casillas Araiza, maestro en Ciencias, ha trabajado sobre Ambientes Inteligentes (AmI), diseñando un Sistema Operativo para IoT (AIOS), construyendo sensores y actuadores para el AmI, sus áreas de interés abarcan los

controladores digitales para la Robótica y la Inteligencia Artificial para la optimización de movimientos y tareas en Robots Manipuladores Industriales.