

Uso de sensores
electroquímicos de bajo
costo para el monitoreo
de la calidad del aire
en el distrito de
San Isidro - Lima - Perú

**Documento de Discusión
CIUP**

DD1705

2017

Ana Luna

Profesor e investigador del CIUP
ae.lunaa@up.edu.pe

Álvaro Talavera

Profesor e investigador del CIUP
ag.talaveral@up.edu.pe

Luis Cano

Centro de Investigación - CIUP
ag.talaveral@up.edu.pe

Las opiniones expresadas en este documento son de exclusiva responsabilidad del autor y no expresan necesariamente aquellas del Centro de Investigación de la Universidad del Pacífico o de la Universidad misma.

The opinions expressed here in are those of the authors and do not necessarily reflect those of the Research Center of the Universidad del Pacifico or the University itself.

Uso de sensores electroquímicos de bajo costo para el monitoreo de la calidad del aire en el distrito de San Isidro - Lima - Perú

Ana Luna¹, Álvaro Talavera², Luis Cano³
Departamento de Ingeniería, Universidad del Pacífico
Lima, Perú

¹ae.lunaa@up.edu.pe, ²ag.talaveral@up.edu.pe, ³l.canovasquez@up.edu.pe

Abstract— En este trabajo se muestran los resultados preliminares del monitoreo y de la estimación de contaminantes atmosféricos en un punto estratégico dentro del distrito de San Isidro, Lima - Perú. Se emplearon sensores electroquímicos de bajo costo, portátiles, inalámbricos y geo-localizables para la captura de los niveles de contaminación que permiten obtener en tiempo real valores confiables que podrían emplearse no sólo para cuantificar la exposición de contaminación atmosférica sino también para prevención y control, e incluso para fines legislativos.

Para la previsión de los niveles de CO_2 y de SO_2 se aplicaron algoritmos de inteligencia computacional, específicamente redes neuronales.

I. INTRODUCCIÓN

En las últimas décadas han sido publicados varios trabajos de investigación en donde se muestra la correlación entre la disminución de la calidad de vida y el aumento de las enfermedades respiratorias y cardiovasculares con la contaminación atmosférica [1]-[2]-[3]. Según el reporte del año 2014 de la Organización Mundial de la Salud (OMS), Lima es una de las ciudades que tiene al aire más contaminado en América Latina. Por tal motivo, el monitoreo de la calidad del aire debería ser una de las prioridades de nuestra sociedad actual. El último reporte del Organismo de Evaluación y Fiscalización Ambiental (OEFA) elaborado en el año 2015, muestra que sólo el 29% de las municipalidades existentes en Lima Metropolitana supervisa y fiscaliza la contaminación del aire en su jurisdicción.

En la actualidad existen diez estaciones fijas de monitoreo de calidad del aire en Lima Metropolitana y el Callao para evaluar permanentemente la contaminación atmosférica. El

Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI) es el ente que informa mensualmente los resultados de dichas estaciones automáticas.

La adquisición de los niveles de contaminación, usualmente se llevan a cabo a través de estaciones estáticas de monitoreo que poseen instrumentos de medición muy precisos y que requieren de un mantenimiento y calibración permanente y cuyo costo supera ampliamente las decenas de miles de dólares cada uno [4]. En consecuencia, esto trae aparejado una gran limitación en el número de redes de monitoreo posibles.

Sin embargo el creciente avance de la tecnología ha permitido el desarrollo de una nueva generación de sensores, económicos y pequeños.

En este trabajo se presenta el diseño, equipamiento y puesta en marcha de una estación de monitoreo de contaminación atmosférica portátil y de bajo costo en el distrito de San Isidro, Lima, Perú. Se detalla además cómo fueron procesados los valores adquiridos y se muestran las gráficas de los valores de los contaminantes en función de la franja horaria registrada. A continuación, se esbozan algunas observaciones, se emplea inteligencia artificial, específicamente redes neuronales para la predicción y validación de los contaminantes críticos medidos y se analizan los resultados obtenidos. Finalmente, en la última sección, se presentan las conclusiones.

II. Teoría

Las Redes Neuronales son un campo dentro de la Inteligencia Artificial que se inspira en las conexiones entre neuronas del cerebro humano, intentando crear modelos artificiales que emplean técnicas algorítmicas convencionales para hallar la solución de un problema en particular. Las redes neuronales son, en síntesis, unidades de procesamiento que intercambian datos o información y que se utilizan para reconocer patrones, como por ejemplo, tendencias financieras. Tienen la capacidad de aprender y mejorar su funcionamiento [5].

El modelo de neurona artificial consta básicamente de un conjunto de entradas de un número determinado de componentes, en forma de vector, que genera una única salida. Existe además, un conjunto de pesos sinápticos que representan la interacción entre las neuronas

pre sináptica y post sináptica. La regla de propagación brinda el potencial post sináptico y la función de activación proporciona el estado de activación de la neurona en función del estado anterior y del valor post sináptico. Finalmente, la función de salida se obtiene a partir del estado de activación.

Una red neuronal artificial (RNA) está compuesta por nodos (elementos del proceso) y conexiones. Cada nodo posee una función de transferencia. Las entradas son externas y las salidas se obtienen a partir de las conexiones salientes de la RNA.

Una RNA posee una determinada estructura que permite visualizar cómo son las conexiones sinápticas de la red. Las neuronas suelen agruparse en capas, una de entrada, la cual recibe los datos del entorno; otra de salida, que proporciona la respuesta de la red a los estímulos de la entrada y capas ocultas que forman parte del procesamiento interno de la red y no tienen contacto directo con el entorno exterior. (Fig. 1).

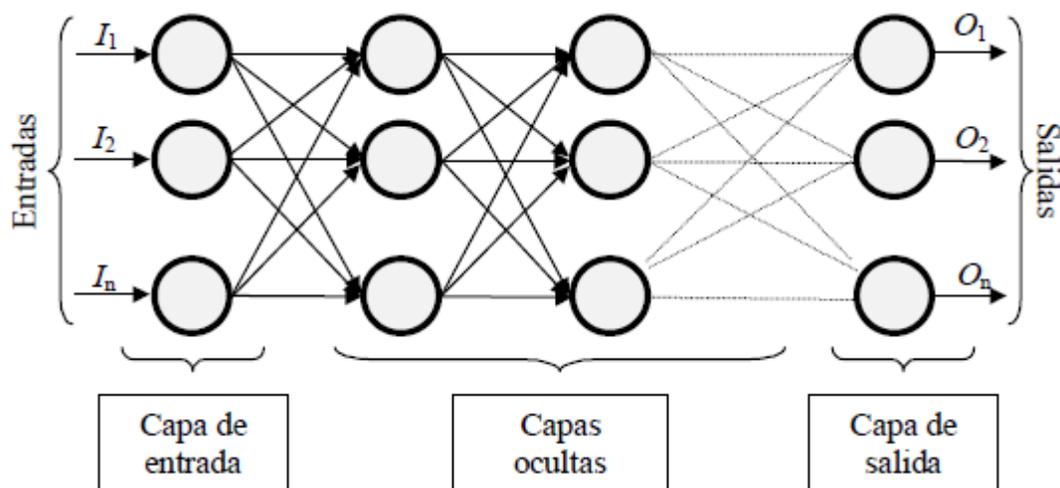


Fig. 1: Ejemplo de una red neuronal totalmente conectada.

El proceso de aprendizaje de una RNA consiste en actualizar los pesos a través de algoritmos de aprendizaje, que es un procedimiento numérico de ajuste de pesos con el fin de minimizar el error cometido.

El algoritmo de entrenamiento empleado en este trabajo fue el que se conoce con el nombre de Levenberg-Marquardt, el cual se aplica principalmente a redes neuronales con varias capas debido a que la velocidad de convergencia es muy rápida, minimizando velozmente la función de error.

Finalizado el proceso de entrenamiento, se debe comprobar si la red neuronal puede resolver el problema que se desea solucionar; es decir, se busca validar el resultado obtenido. Para ello, se requiere de otro conjunto de datos, denominado conjunto de validación o testeo. Cada ejemplo del conjunto de evaluación contiene los valores de las variables de entrada, con su correspondiente solución tomada; pero la solución no se le otorga a la red neuronal. Luego se compara la solución estimada por la red con la real para finalizar el proceso de validación.

Para evaluar el desempeño de la red se usó como indicador el error porcentual absoluto medio (MAPE o *Mean Absolute Percentage Error*), que mide el tamaño del error (absoluto) en términos porcentuales. La ecuación (1) fue empleada para el cálculo del MAPE:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|x_i - \bar{x}_i|}{|x_i|} \quad (1)$$

Siendo N el número total de valores; x_i y \bar{x}_i los valores reales y previstos por la red respectivamente.

También se empleó la raíz del error cuadrático medio o RMSE (Root Mean Squared Error), la cual es una medida de desempeño cuantitativa utilizada para evaluar métodos de pronóstico, es un estimador que mide el promedio de los errores al cuadrado, es decir, la diferencia entre el estimador y lo que se estima, evaluando la calidad de un conjunto de predicciones en cuanto a su variación y el grado de sesgo. La fórmula de cálculo del RMSE se muestra en la ecuación (2):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x}_i)^2} \quad (2)$$

III. MATERIALES Y MÉTODOS

Las mediciones se llevaron a cabo en las instalaciones de la Municipalidad de San Isidro (Augusto Tamayo 180) Lima, Perú (Fig. 2). Las coordenadas geográficas en el Distrito de

San Isidro donde se ubicaron los sensores son: Latitud: -12.1167, Longitud: -77.05 y Altura (m.s.n.m): 109 Metros (Base: Parque el Olivar).

El distrito de San Isidro tiene una extensión de 9.78 km² y una población de aproximadamente 58.056 habitantes.

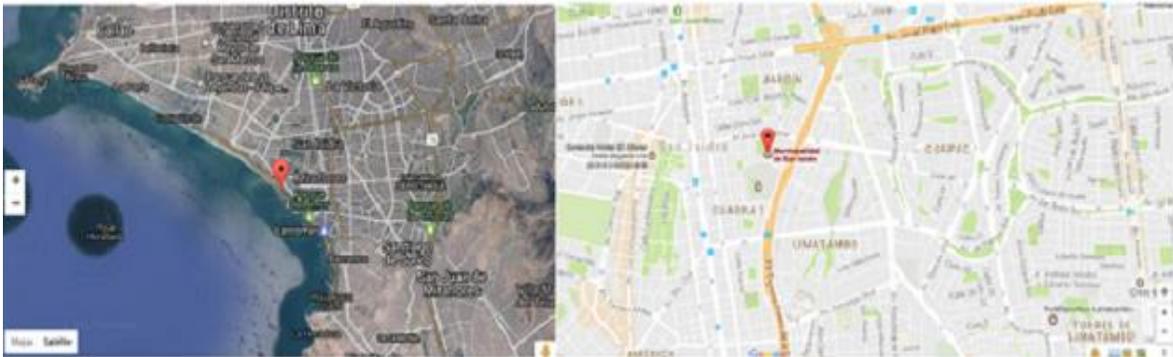


Fig. 2: Mapa donde se observa el punto en el cual fueron instalados los sensores de contaminación atmosférica y sonora.

A III. Sensores electroquímicos de bajo costo

Los sensores outdoor empleados para la medición de calidad de aire son de la marca *αSense* (Essex – Reino Unido) [6]-[7]-[8]. Son inalámbricos, alimentados por una batería y un panel solar. Poseen conexión *wifi* (interfaz celular GSM) además de ser geo-localizables (GPS incorporado). Los datos se envían a la nube y pueden leerse desde cualquier PC con conexión a internet (M2M). Son sensores electroquímicos que poseen 4 electrodos diseñados para medir los niveles del gas en nmol/mol. El primero de los electrodos se denomina “*Electrodo de Trabajo*”, el segundo se llama “*Electrodo de Referencia*”, el tercero es el “*Electrodo Contador*” y el último, el “*Electrodo Auxiliar*” se utiliza para corregir el cero ante los cambios de corriente. Éste no está en contacto con el gas; por lo tanto, proporciona información útil sobre el efecto de la temperatura ambiental. Cada sensor brinda dos señales, la segunda de ellas es la señal de fondo del electrodo que debe ser restada a los valores suministrados por el sensor del *Electrodo de Trabajo*.

Los contaminantes atmosféricos registrados fueron: CO_2 , VOC (alcoholes, aldehídos, hidrocarburos alifáticos, aminas, hidrocarburos aromáticos, CH_4 , LPG, ketones y ácidos orgánicos), CO , SO_2 , Ozono y Dióxido de Nitrógeno ($O_3 + NO_2$); y las variables

meteorológicas adquiridas en forma simultánea fueron la temperatura ambiental, la humedad relativa y la presión barométrica (Fig. 3).



Fig. 3: Sensores de calidad de aire (CO_2 , VOC , SO_2 , $O_3 + NO_2$, CO) y meteorológicos: temperatura ambiental, humedad relativa y presión barométrica.

B III. Mediciones de campo

Los datos almacenados para los diferentes contaminantes atmosféricos fueron registrados desde las 8:00 am hasta las 12:30 pm durante los días miércoles 5, jueves 6, viernes 7, lunes 10, martes 11 y miércoles 12 de abril de 2017. Se registra 1 dato por minuto, dando como máximo un total de 270 valores registrados diariamente.

La información adquirida para los contaminantes de medición indirecta, CO , SO_2 y $O_3 + NO_2$, debe procesarse. Para ello, se generaron varios códigos en lenguaje de programación Python; el primero de ellos realiza la conversión de los datos registrados en unidades de voltaje y proporcionados por el dashboard *Valarm* a valores en partes por millón (ppm) usando la ecuación (3) que se muestra a continuación,

$$Valor (ppm) = \frac{(WE - WE_0) - (AE - AE_0)}{Sensibilidad} \quad (3)$$

donde WE son los datos registrados por el “Electrodo de Trabajo”, AE son los valores del “Electrodo Auxiliar” y WE_0 y AE_0 corrigen las señales de fondo de los respectivos electrodos. El valor de la sensibilidad para cada contaminante se obtiene a partir de la siguiente fórmula (ec. 4):

$$Sensibilidad = WE_{sensitivity} \left(\frac{nA}{ppm} \right) * Ganancia \left(\frac{mV}{nA} \right) \quad (4)$$

siendo los valores de sus factores, datos aportados por el fabricante de los sensores.

La siguiente etapa consiste en el tratamiento de los datos, que ahora están expresados en unidades de ppm. El nuevo programa elimina tanto los valores negativos como los ceros y también aquellos valores que se apartan tres veces del valor de la desviación estándar correspondiente a la media de cada uno de los contaminantes respectivamente. Los valores descartados son reemplazados por aquellos obtenidos mediante una interpolación lineal entre el dato previo y posterior de dicho valor registrado. En el caso de los primeros y últimos valores que han sido eliminados, se los completa con el dato del promedio de la adquisición.

Finalmente, se procesan todos los datos obtenidos y tratados hasta el momento con un tercer programa que gráfica los niveles de contaminación en función del tiempo, además inserta en cada figura el valor de las variables meteorológicas (presión, humedad y temperatura) y el Valor del Estándar de Calidad Ambiental (ECA) para cada contaminante.

IV. RESULTADOS

Los valores de los niveles de concentración de los contaminantes medidos se muestran, a modo de ejemplo, sólo para uno de los días de adquisición en la Fig. 4. El resto de los días medidos son cualitativamente análogos y los respectivos resultados de sus valores medios se resumen en la Fig. 5.

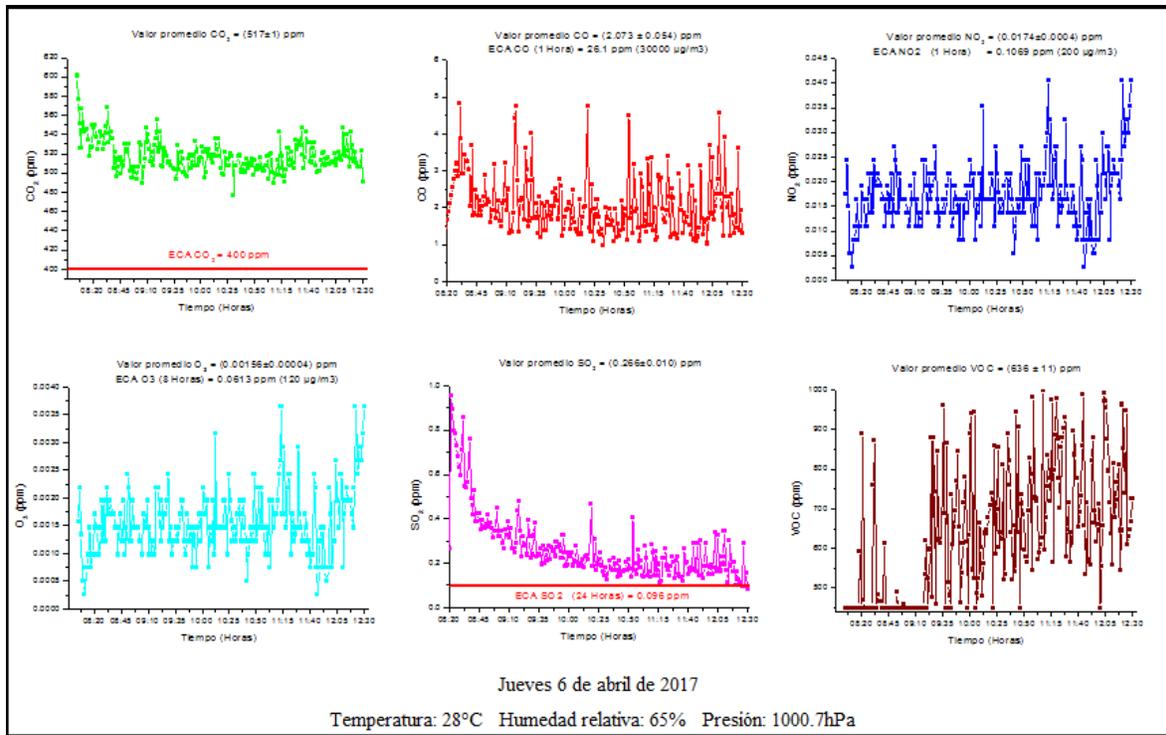


Fig 4: Series temporales de los niveles de contaminantes medidos en la franja horaria de 8:00 am a 12:30 pm el día jueves 6 de abril de 2017

En la Tabla I se informan las variables meteorológicas de cada uno de los días en los cuales se realizaron las mediciones.

Variables meteorológicas	5 de abril de 2017	6 de abril de 2017	7 de abril de 2017	10 de abril de 2017	11 de abril de 2017	12 de abril de 2017
Temperatura	30°C	28°C	32°C	32°C	29°C	32°C
Humedad relativa	62%	65%	60%	60%	64%	59%
Presión	999hPa	1000.7 hPa	999.8hPa	1000hPa	1000hPa	999hPa

Tabla I: Valores medidos de la temperatura, humedad relativa y presión en los días y horas en los que se registraron los niveles de concentración de los contaminantes atmosféricos.

En la Fig. 5 se observan los niveles medios de contaminantes atmosféricos registrados en la franja horaria de 8:00 am a 12:30 pm durante los días especificados en las gráficas.

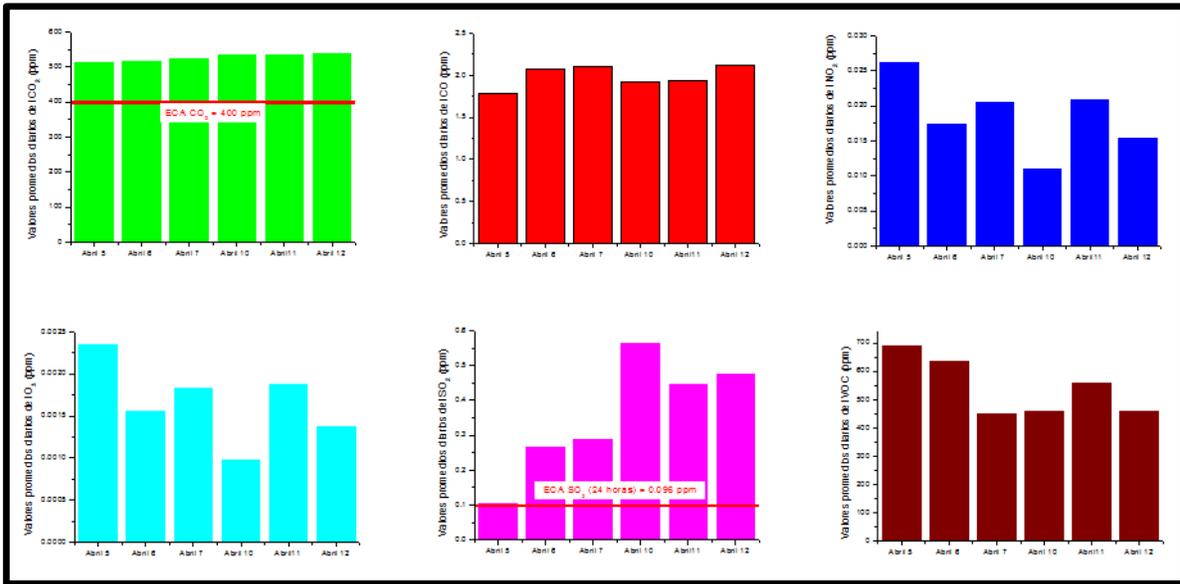


Fig 5: Valores medios de niveles de contaminantes atmosféricos diarios (CO_2 , CO , NO_2 , O_3 , SO_2 y VOC).
 Franja horaria de registro: 8:00 am a 12:30 pm. Año 2017.

Durante las mediciones realizadas en el distrito de San Isidro se observa que el valor promedio del dióxido de carbono excede en casi un 32% los valores máximos dentro de los estándares de calidad de aire para dicho contaminante (Figs. 4 y 5). Existe una relación directa entre el calentamiento global o cambio climático y el aumento de las emisiones de gases de efecto invernadero provocado por las sociedades humanas tanto industrializadas como en desarrollo. Los últimos estudios han demostrado que la concentración de CO_2 en la atmósfera está aumentando de forma constante debido al uso de carburantes fósiles como fuente de energía [10]. Esto provoca cambios importantes sobre los seres vivos y los ecosistemas, como así también consecuencias económicas, sociales y ambientales de gran magnitud (la temperatura media de la superficie terrestre se ha incrementado, aumentaron los fenómenos de erosión y salinización en áreas costeras, se intensificaron las enfermedades infecciosas, etc.).

Tanto el dióxido de carbono como el dióxido de azufre son contaminantes gaseosos primarios y se emiten directamente a la atmósfera. El SO_2 registra también valores muy por encima de

los estándares de calidad (Figs. 4 y 5), el promedio de los valores medidos supera en más de un 270% el valor informado por el ECA.

Son variadas las fuentes que producen estos compuestos químicos, pero las principales fuentes artificiales son la quema de combustible fósil y la proveniente de fábricas, industrias, centrales eléctricas y los automóviles.

Cuando el dióxido de azufre está en la atmósfera reacciona con la humedad y forma aerosoles de ácido sulfúrico y sulfuroso que luego forman parte de la llamada lluvia ácida y sus componentes son altamente nocivos para la vegetación.

El SO_2 también ataca a los materiales de construcción que suelen estar formados por minerales carbonatados. Además, el dióxido de azufre forma sulfatos, y la exposición a éstos como a los ácidos derivados del SO_2 , es de extremo riesgo para la salud debido a que ingresan directamente al sistema circulatorio humano a través de las vías respiratorias, siendo es muy irritante para los pulmones.

El exceso de SO_2 trae aparejado consecuencias graves a nivel salud, como por ejemplo, el aumento de la cantidad de hospitalizaciones debido a enfermedades pulmonares obstructivas crónicas (EPOCs) tal como se registra en la referencia [10].

En el artículo [11] también se demuestra el aumento de la incidencia de rinitis alérgica, bronquitis y asma, en niños como consecuencia de la contaminación por SO_2 . Más aún, en el trabajo [12] se analizan diferentes efectos de las exposiciones a largo plazo a SO_2 , entre otros, sobre todo en adultos jóvenes que son gravemente afectados por el asma. Sin duda, lo que respiramos afecta nuestra salud, y puede aumentar la morbilidad y mortalidad en personas mayores y niños; por lo que debería ser prioritario reducir la contaminación del aire en pos de una mejora de la salud.

A IV. Redes neuronales

Este modelo de inteligencia computacional fue usado para pronosticar los niveles de concentración de los dos contaminantes atmosféricos que sobrepasan los valores de ECA establecidos, el CO_2 y el SO_2 (Figs. 4 y 5).

Para la predicción del dióxido de carbono se construyó, como primera medida la red neuronal. La topología óptima hallada para la red fue de 14 neuronas en la primera capa oculta y de 3 neuronas en la segunda capa oculta (Fig. 6). Éste resultado se obtuvo mediante un algoritmo de búsqueda (en el software RapidMiner) en donde se probaron todas las combinaciones posibles entre neuronas en una estructura de 2 capas ocultas y un máximo de 20 neuronas en cada capa. Los datos de entrenamiento de la red empleados fueron las concentraciones de los contaminantes atmosféricos medidos durante los 5 días anteriores al día de predicción, estos datos fueron divididos en 3 conjuntos, 70% fueron usados para el entrenamiento, 20% fueron considerados para la validación y el 10% restante fueron tenidos en cuenta para el teste. El algoritmo de entrenamiento fue Levenberg-Marquardt. La convergencia se dio en la iteración número 14, en la que ya no hubo variación significativa en el error del entrenamiento de la red entre el paso previo y el posterior a esta última iteración.

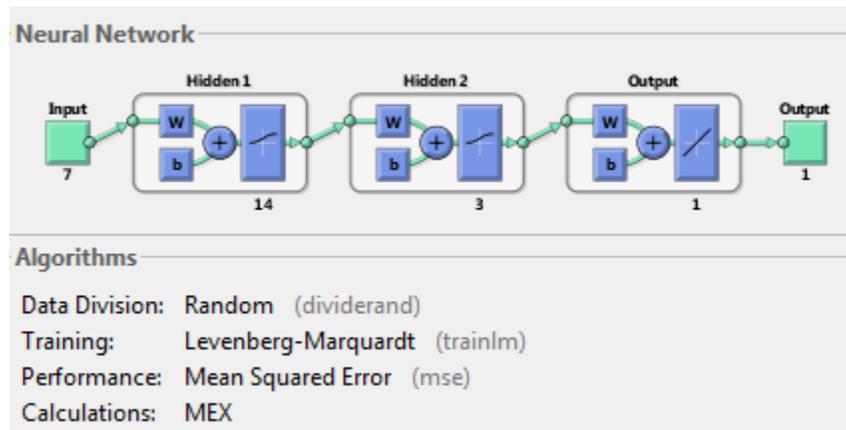


Fig. 6: Arquitectura de la red neuronal empleada para la predicción del CO_2 . Se puede apreciar que la convergencia se dio en la iteración número 14, y ya no hubo variación significativa entre la performance obtenida en una iteración previa y la iteración inmediatamente posterior.

En la Fig. 7 se observa la gráfica de los valores medidos y de la predicción de los niveles de concentración del CO_2 para el día miércoles 12 de abril de 2017. Éstos últimos se obtuvieron a partir del entrenamiento previo del modelo con la incorporación de los valores medidos del resto de los contaminantes salvo el CO_2 . Los datos de temperatura, humedad relativa y

presión atmosférica también fueron considerados. El RMSE obtenido fue de 20 ppm y el MAPE alcanzó casi el 3%.

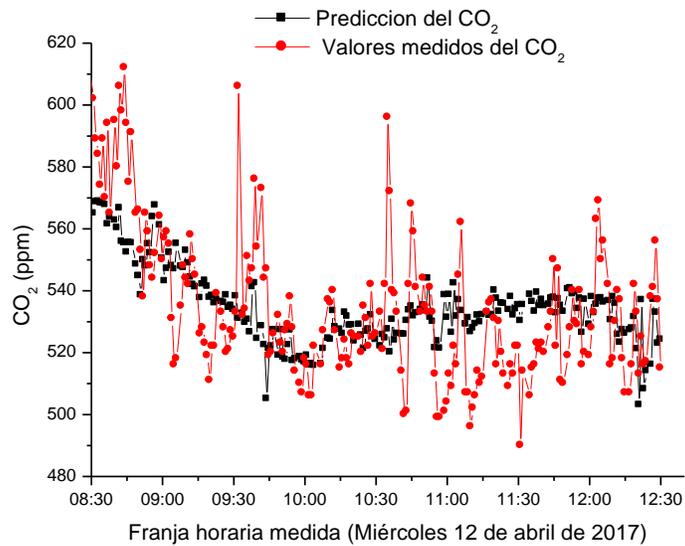


Fig. 7: Pronóstico del dióxido de carbono.

Para encontrar la arquitectura óptima de la red neuronal empleada para la predicción de los niveles de concentración del SO_2 se usó nuevamente el algoritmo de búsqueda probando todas las combinaciones posibles entre neuronas en una estructura de 2 capas ocultas y un máximo de 20 neuronas en cada capa. El resultado fue una red compuesta por 8 neuronas en la primera capa oculta y 5 neuronas en la segunda capa oculta (Fig. 8).

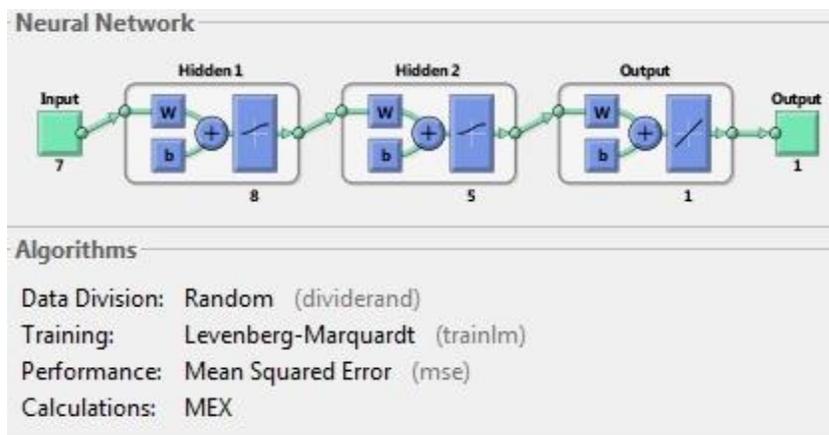


Fig. 8: Arquitectura de la red neuronal empleada para la predicción del SO_2 .

Los datos de entrenamiento de la red fueron las concentraciones de los contaminantes de 5 días previos: miércoles 5, jueves 6, viernes 7, lunes 10 y martes 11 de abril de 2017, y se predijo los niveles de *ppm* (partes por millón) del SO_2 del día miércoles 12 de abril de 2017. Los valores medidos con los sensores de bajo costo fueron divididos en 3 conjuntos, el 70% fue empleado para el entrenamiento, el 20% se usó para validación y el 10% restante para el teste. El algoritmo de entrenamiento elegido, como se explicó en la sección II fue el de Levenberg-Marquardt. La convergencia se logró en la iteración número 12.

En la Tabla II se observan los resultados del MAPE y del RMSE obtenidos para las predicciones de los niveles de concentración del dióxido de azufre del día miércoles 12 de abril de 2017 entre las 8:30 am y 12:30 pm. La diferencia entre cada una de ellas son los valores de entrada tomados en cuenta por la red neuronal previamente entrenada, los cuales se marcan con una cruz (X) en la Tabla II. En todos los casos las variables meteorológicas: temperatura, humedad relativa y presión atmosférica fueron consideradas en el entrenamiento.

VARIABLES	Predicción 1 del SO_2	Predicción 2 del SO_2	Predicción 3 del SO_2	Predicción 4 del SO_2	Predicción 5 del SO_2	Predicción 6 del SO_2
SO_2						
CO	X		X	X	X	X
CO ₂	X	X		X	X	X
NO ₂	X	X	X		X	X
O ₃	X	X	X	X		X
VOC	X	X	X	X	X	
MAPE	45%	49%	51%	51%	29%	54%
RSME (ppm)	0.30	0.36	0.43	0.36	0.27	0.42

Tabla II: Resultados del MAPE y del RSM para cada predicción del SO_2 .

Como se puede observar en la Tabla II, la predicción del dióxido de azufre que arrojó los valores de MAPE y de RSME más bajos, fue aquella en la cual no se contempló el O_3 (Fig. 9).

El coeficiente de correlación lineal entre la predicción y los valores medidos de SO_2 fue de 0.89.

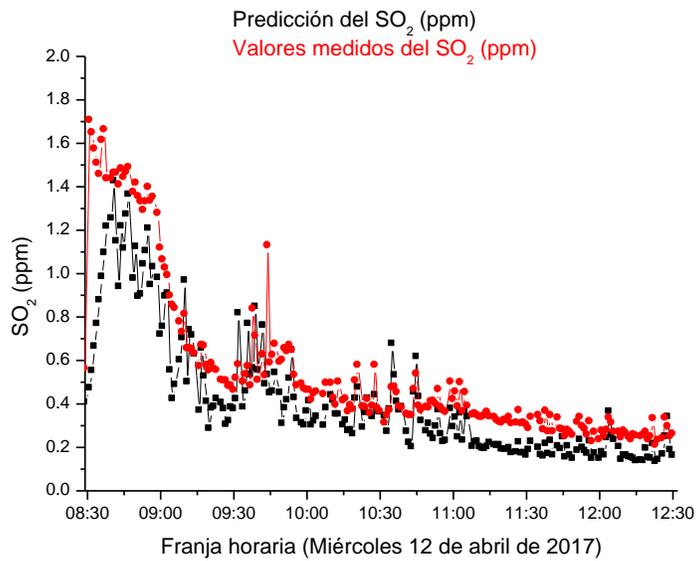


Fig. 9: Pronóstico del dióxido de azufre.

Por lo tanto, como primera aproximación, el empleo de inteligencia artificial teniendo sensores atmosféricos de bajo costo es una herramienta potencial para pronosticar niveles de concentración confiables de contaminantes.

V.CONCLUSIONES

Los experimentos de campo son esenciales para poder comprender ciertos aspectos del tiempo y el clima de una región. En este *working paper* se mostraron y analizaron los datos adquiridos de diversos contaminantes atmosféricos en el distrito de San Isidro.

Los sensores de bajo costo empleados en este trabajo tienen un gran potencial para ser usados como complemento de las escasas estaciones estáticas de monitoreo; aumentando, de esta manera, la resolución espacial de las mediciones. Si bien las mediciones de los sensores electroquímicos no necesariamente poseen la precisión o exactitud de los instrumentos tradicionales in situ, son lo suficientemente versátiles y económicos para usarlos en la adquisición de valores de contaminación atmosférica y obtener información preliminar sobre las emisiones provenientes de fuentes fijas y móviles e incluso podrían identificarse en

tiempo real los puntos críticos de contaminación atmosférica, es decir, las áreas con deterioro de la calidad del aire y proponer medidas para revertir esta situación ambiental, o bien mitigar los episodios críticos de contaminación atmosférica sobre los asentamientos poblacionales.

RECONOCIMIENTOS

Quisiera agradecer a la Universidad del Pacífico y en particular al Departamento de Ingeniería por la compra de los sensores de contaminación atmosférica y sonora; y de las tarjetas SIM usadas para la transmisión de datos. También quisiera transmitir mi gratitud a las Sras. Jimena Sánchez Velarde, Directora de datosabiertosperu.com y Pamela Olenka Peña, Gerente de Sostenibilidad de la Municipalidad de San Isidro, quienes autorizaron el uso de las instalaciones dentro de la Municipalidad permitiendo la realización de este trabajo de investigación.

REFERENCIAS

- [1] Landrigan, P. J. (2017). Air pollution and health. *The Lancet Public Health*, 2(1), e4-e5.
- [2] Day, O., Day, A. M., Day, P. M., Pope, C. A., Anderson, R., Brunekreef, B., ... & Tripovich, J. (2013). Air pollution and health.
- [3] Wong, G. W. (2014). Air pollution and health. *The Lancet Respiratory Medicine*, 2(1), 8-9.
- [4] Piedrahita, R., Xiang, Y., Masson, N., Ortega, J., Collier, A., Jiang, Y., ... & Shang, L. (2014). The next generation of low-cost personal air quality sensors for quantitative exposure monitoring. *Atmospheric Measurement Techniques*, 7(10), 3325.
- [5] Simon Haykin. *Neural networks: A comprehensive foundation*: Macmillan college publishing company. New York, 1994.
- [6] <http://www.alphasense.com/WEB1213/wp-content/uploads/2015/04/COB41.pdf>
- [7] <http://www.alphasense.com/WEB1213/wp-content/uploads/2017/05/SO2-B4.pdf>
- [8] <http://www.alphasense.com/WEB1213/wp-content/uploads/2017/03/OX-B431.pdf>
- [9] Martínez Ataz, E., & Díaz de Mera Morales, Y. (2004). Contaminación atmosférica.
- [10] Ghozikali, M. G., Mosaferi, M., Safari, G. H., & Jaafari, J. (2015). Effect of exposure to O₃, NO₂, and SO₂ on chronic obstructive pulmonary disease hospitalizations in Tabriz, Iran. *Environmental Science and Pollution Research*, 22(4), 2817-2823.
- [11] Chiang, T. Y., Yuan, T. H., Shie, R. H., Chen, C. F., & Chan, C. C. (2016). Increased incidence of allergic rhinitis, bronchitis and asthma, in children living near a petrochemical complex with SO₂ pollution. *Environment International*, 96, 1-7.
- [12] Greenberg, N., Carel, R. S., Derazne, E., Bibi, H., Shpriz, M., Tzur, D., & Portnov, B. A. (2016). Different effects of long-term exposures to SO₂ and NO₂ air pollutants on asthma severity in young adults. *Journal of Toxicology and Environmental Health, Part A*, 79(8), 342-351.