

MÉTODOS DE BAJO COSTO PARA ESTUDIO PRELIMINAR DEL MATERIAL PARTICULADO EN EL CENTRO-NORTE DEL CONURBANO BONAERENSE

LOW-COST METHODS TO PARTICULATE MATTER PRELIMINARY STUDY IN THE CENTER-NORTH OF BUENOS AIRES SUBURBS

A. F. Scagliotti*¹ y G. A. Jorge¹

¹Instituto de Ciencias - Universidad Nacional de General Sarmiento - CONICET,
J. M. Gutierrez 1150 - (1613) Buenos Aires - Argentina.

Recibido: 07/09/2021; Aceptado: 21/11/2021


La calidad del aire es uno de los mayores problemas ambientales de la actualidad, y las partículas en el aire son un indicador muy estudiado dados sus impactos sobre la salud y el clima. El costo de los equipos regulatorios de medición lleva a que haya una limitada disponibilidad de información en muchas partes del mundo, como sucede en Argentina. Este trabajo propone un modelado de material particulado a partir de Redes Neuronales Artificiales, alimentado con datos de equipos de bajo costo desarrollados y utilizados para tal fin. De esta manera, se presenta un estudio preliminar de la calidad del aire en el Centro-Norte del conurbano bonaerense, aportando nueva información sobre cantidades y tipos de partículas en una región sin antecedentes históricos. Se encontraron mayoritariamente partículas gruesas en bajas concentraciones y se desarrolló un modelo de predicción de material particulado con buenas prestaciones.

Palabras Clave: calidad del aire, mediciones de bajo costo, redes neuronales.

Air quality is one of the biggest environmental problems today, and airborne particles are a well-studied indicator given their impacts on health and climate. The cost of regulatory measurement equipment leads to limited information availability in many parts of the world, as in Argentina. This work proposes modeling of particulate matter from Artificial Neural Networks, fed with data from low-cost equipment developed and used for this purpose. In this way, a study of air quality in the Center-North of the Buenos Aires suburbs is presented, providing new information on quantities and types of particles in a region without historical antecedents. Coarse particles were mostly found at low concentrations and a prediction model for particulate matter with good performance was developed.

Keywords: air quality, low cost measurements, neural networks.

<https://doi.org/10.31527/analesafa.2022.33.1.18>

 ISSN 1850-1168 (online)

I. INTRODUCCIÓN

Según la Organización Mundial de la Salud, mueren prematuramente 4.2 millones de personas por año debido a la contaminación del aire, mientras que más del 80% de los habitantes de áreas urbanas con monitoreo están expuestos a niveles que exceden los límites establecidos, especialmente en países en desarrollo [1]. Es por ello que resulta imprescindible avanzar en la generación de conocimiento y en la comprensión de los procesos involucrados al respecto, que son herramientas indispensable en aplicaciones regulatorias, de investigación científica y forenses [2]. Uno de los principales indicadores de la calidad del aire (CA) son las partículas que permanecen suspendidas en la atmósfera, las cuales también tienen el potencial de impactar en el clima [3]. Cercanas a la superficie se caracterizan por su diámetro aerodinámico equivalente, recurriendo a la simplificación de partículas esféricas con densidad igual a la unidad, como material particulado (PM): PM_{10} (para partículas de tamaños menores a $10 \mu\text{m}$), $PM_{2.5}$ (para partículas de tamaños menores a $2.5 \mu\text{m}$) y PM_1 (para partículas de tamaños menores a $1 \mu\text{m}$). Por otro lado, en una columna atmosférica se denominan aerosoles y se caracterizan comúnmente con el espesor óptico de aerosoles (AOD), que cuantifica la

extinción de la luz solar del tope de la atmósfera hasta la superficie debida a la presencia de partículas. El comportamiento de las partículas en la atmósfera depende tanto de las características de la zona en estudio como de las variables meteorológicas a diferentes escalas espaciales y temporales [4].

Respecto a la disponibilidad de información sobre CA, las mediciones de contaminantes a nivel de superficie requieren instrumentos muy costosos, por lo que en muchas ciudades del mundo se cuenta con una cobertura limitada y una distribución irregular o inexistente de estaciones de monitoreo [5]. Esta problemática puede mitigarse actualmente gracias a la disponibilidad de sensores de bajo costo (LCS) para el monitoreo de la CA [3]. Por supuesto, esta tecnología tiene sus limitaciones y los sensores deben ser calibrados/validados con instrumentos de referencia.

Otro enfoque complementario para estudiar la CA es el empleo de modelos numéricos y estadísticos. Dentro del abanico de posibilidades, los algoritmos de aprendizaje automático o Redes Neuronales Artificiales (ANN) han mostrado tener un alto potencial para extraer nueva información de una serie de datos [6]. Se trata de modelos no paramétricos usados para regresión y/o clasificación, robustos en la interpretación de relaciones no lineales entre variables.

* ascagliotti@campus.ungs.edu.ar

Este tipo de modelos ha sido ampliamente empleado para realizar predicciones y caracterizaciones de contaminantes en el aire [6]. La sede central de la Universidad Nacional de General Sarmiento (UNGS), donde se realizaron los desarrollos y mediciones para este estudio, se encuentra en la región Centro-Norte del conurbano bonaerense (en una zona sin cobertura histórica de mediciones de CA), a poco más de 30 km del centro de la Ciudad Autónoma de Buenos Aires (CABA). Diversos motivos hacen a la población de esta zona particularmente vulnerable a la CA [7].

Este trabajo muestra la combinación de diferentes enfoques de bajo costo en pos de estudiar la CA en la región de estudio, en cuanto a partículas en el aire. En primera instancia, se describe el desarrollo y monitoreo con un equipo de bajo costo para medición de PM “ECAUNGS”, y se complementa con una simulación desde un enfoque físico. Luego, se presentan mediciones de propiedades ópticas de aerosoles con un fotómetro solar de bajo costo. Finalmente, se integran los métodos e información recopilada con un modelo de predicción de PM basado en ANN. Se eligió como objetivo el $PM_{2.5}$, dado que el interés actual de investigación en CA para partículas se encuentra centrado en fracciones finas por sus efectos sobre la salud [8], y la precisión de los LCS es mayor en esta fracción de tamaños [9].

II. MÉTODOS

Simulaciones de distribuciones de partículas

Con el fin de contar con una referencia en torno a los tamaños de partículas que afectan a las señales de un sensor de PM, se utilizó la librería “opetim” [10] para lenguaje Python que permite simular sensores de PM y programar a medida diferentes distribuciones. Se muestran las funciones de distribución acumulada para aerosoles de ambientes típicos, construidas en base a la suma de modos lognormales con parámetros (números de concentración, medianas del diámetro de partículas y desviación estándar de tamaños) extraídos de Seinfeld & Pandis (2016) [11].

Desarrollo de equipo de bajo costo ECAUNGS y mediciones de PM

Para medir PM en superficie, se diseñó y desarrolló un prototipo de mini-estación de CA de bajo costo, que fue denominado ECAUNGS.

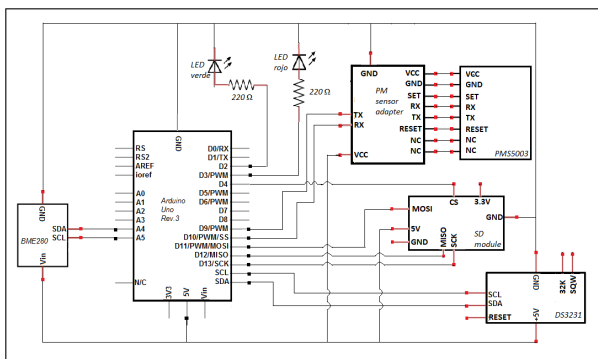


FIG. 1: Circuito de conexiones de los sensores, actuadores y la placa de control.

El equipo cuenta con un sensor de humedad, presión

y temperatura BME280 (seleccionado luego de una intercomparación con diferentes alternativas [12]) y otro de PM con dispersión láser PMS5003, previamente caracterizado y validado con equipo calibrado. La estación se controla a través de una placa Arduino UNO R3 y cuenta con módulos de reloj y SD para almacenamiento de los datos. La Fig. 1 muestra el circuito básico del desarrollo.

Asimismo, cuenta con un abrigo meteorológico para el sensor de humedad, presión y temperatura. Posee una entrada de aire que se encuentra conectada a través de una manguera al sensor de PM, un LED indicador verde para indicar la frecuencia de muestreo y otro de color rojo para indicar alguna falla en el funcionamiento. Todo el equipo puede alimentarse con una fuente switching de 9 V y 1 A, pero con el fin de darle independencia energética se implementó un sistema de alimentación a través de un panel solar de 10 W (tensión de 18.2 V y corriente de 0.52 A, operando en potencia máxima) conectado a través de un regulador a una batería de gel de 12 V y 7 Ah. En un reservorio digital creado para tal fin [13], se puede consultar el código de control desarrollado para ECAUNGS en lenguaje C++ y ejecutado en la “Interfaz De Usuario” de Arduino. La Fig. 2 muestra las partes del circuito central y la instalación de ECAUNGS.




FIG. 2: Componentes físicos del circuito central e instalación final del equipo. a) Módulos, sensor de PM y placa central. b) Presentación de la instalación final del prototipo ECAUNGS. El panel solar se ubica apuntando al Norte con unos 15° de inclinación respecto a la superficie, y por debajo se ubican la central y el abrigo.

Finalmente, se instaló ECAUNGS en un domicilio particular cercano a la UNGS y se realizaron mediciones entre junio de 2019 y enero de 2021. El período de muestreo de ECAUNGS se estableció en aproximadamente 1 segundo (que varía levemente por tiempos de comunicación entre los componentes). En total, se contó con 165 días de mediciones, con un total de 13711356 líneas de datos (cada línea con datos de fecha en formato DD/MM/AAAA, hora en formato HH:MM:SS, PM_1 , $PM_{2.5}$, PM_{10} , humedad, presión y temperatura). Se practicó un control de calidad de datos partiendo de la frecuencia de muestreo original, eliminando datos fuera de rango ($>500 \mu\text{g m}^{-3}$) y no numéricos. Luego, se buscaron en la serie temporal pendientes elevadas en búsqueda de datos atípicos (para ello se determinó como dato sospechoso a aquel que involucre una diferencia con su dato vecino mayor a 2 desviaciones estándar de la serie completa). Este método se implementó posteriormente en

una base minutal (tras aplicar un promedio móvil a las series) y horaria, como se recomienda en Bulot et. al (2019) [9].

Mediciones fotométricas

Se llevaron a cabo mediciones manuales de AOD en el sitio de la UNGS con un fotómetro solar calibrado de bajo costo CALITOO (identificación #1703-0304) del programa “Global Learning and Observation to Benefit the Environment” (GLOBE), durante el mismo periodo de medición de ECAUNGS. La descripción del instrumento, método de medición y un primer estudio de propiedades ópticas de aerosoles puede consultarse en Scagliotti y Jorge (2020) [14]. Se contó con 136 mediciones del periodo junio de 2019 a enero de 2021, que fueron utilizadas en el modelado con ANN.

Modelado ANN con datos adquiridos

Las ANN consisten en un conjunto de unidades simples de procesamiento que se comunican a través de múltiples conexiones. El modelo de Perceptrón Multicapa (MLP, por su denominación en inglés "Multi Layer Perceptron") es la forma más utilizada de ANN [6]. El modelo se entrena con diferentes variables de entrada (predictores) y la serie de la variable objetivo (a predecir), de esa manera “aprende” las relaciones en un proceso que divide a los datos en un porcentaje utilizado para el entrenamiento, otro para la validación del modelo y un último para una prueba final (en este caso, se utilizó 60%, 20% y 20%, respectivamente). La estructura básica consta de una capa de entrada, una o varias ocultas y una de salida.

La Fig. 3 muestra un esquema básico de una ANN tipo MLP con una sola entrada (neurona i) y una sola neurona oculta k de procesamiento. A la información de entrada se le asigna un peso $\omega_{i,k}$ y se le suma un sesgo b_k a través de una función F_k en la neurona oculta, luego el resultado se asigna a una neurona de salida o . Normalmente hay varias neuronas de entrada y varias ocultas, en cuyo caso cada entrada interactúa con todas las neuronas ocultas y el resultado final surge de la suma de cada salida. A cada iteración (llamada época), la red compara el valor deseado con el adquirido a partir de todos los datos de entrada y calcula un error que realimenta el modelo para ajustar los pesos de las neuronas, todo controlado por una regla de aprendizaje. Cuando se alcanza un mínimo de error, el entrenamiento se detiene.




FIG. 3: Representación de una red neuronal MLP con una neurona de entrada i , una neurona oculta k y una neurona o en la última capa con una salida y_o . La información fluye de izquierda a derecha. Una época o iteración involucra una cantidad de comparaciones igual en número a la cantidad de datos de entrada.

Se implementó un modelo integrador de tipo ANN MLP para predecir $PM_{2.5}$ en el Centro-Norte del conurbano bonaerense y se consideraron como entradas las medias horarias de las mediciones de ECAUNGS y del fotómetro solar, es decir los promedios por hora durante el periodo de medición de ECAUNGS. Además de otras representativas a nivel regional de concentraciones de contaminantes y meteorología de la estación de monitoreo de CA de ACUMAR EMCI en Dock Sud [15], y datos de asimilación del NOAA [16]. Luego de testear el modelo con las diferentes variables disponibles, se seleccionaron los siguientes predictores: $PM10acu$ (PM_{10} de ACUMAR); $Uacu$ (componente zonal del viento calculada con datos de viento de ACUMAR); $Vacu$ (componente meridional del viento calculado con datos de viento de ACUMAR); BLH (altura de capa de mezcla del NOAA); $AODungs$ (AOD medido con fotómetro solar); $meses$ (mes del año de cada medición de ECAUNGS); $hora$ (hora del día de cada medición de ECAUNGS).

El objetivo del modelo es predecir $PM_{2.5}$ horario, por lo que se entrenó con esa variable medida por ECAUNGS como objetivo y se utilizaron datos horarios entre junio de 2019 y enero de 2021 del resto de las variables para entrenar el modelo. También se buscó optimizar la arquitectura y los parámetros de la red. Se utilizó el “toolbox” de Redes Neuronales en lenguaje GNU OCTAVE para el desarrollo.

III. RESULTADOS

Se integraron las distribuciones volumétricas de partículas típicas simuladas con “opcsim” para obtener las cargas máxicas por unidad de volumen (concentraciones C) en función del tamaño de partículas (normalizado por la densidad δ). La Fig. 4 muestra las funciones de distribución acumulada de estos resultados. Se pueden interpretar algunas características que influyen en las señales del sensor de PM, especialmente las fracciones entre los valores de diferentes rangos de tamaños. Si se realiza el cociente entre los valores de masa total de PM_{10} y PM_1 , se obtiene una magnitud (que llamaremos $PM10/I$) que aporta información sobre la fracción de tamaños de partículas presentes. En el caso urbano, se puede observar que la razón es muy cercana a 1, lo que significa que domina la fracción fina (ya que el valor máximo se alcanza para diámetros cercanos a $1 \mu m$). Las partículas de zonas rurales en general parecen tener una cantidad más considerable de partículas gruesas, por lo que la razón $PM10/I$ es mayor y aproximadamente igual a 3. La distribución continental, referida a zonas profundamente adentradas en el continente, también tiene una fracción gruesa considerable como la rural, pero con un mayor pico en el modo fino (su $PM10/I$ es cercano a 1.9). Los aerosoles marinos poseen aun una mayor diferencia marcada entre los modos fino y grueso que el tipo rural ($PM10/I$ cercano a 5.5). La distribución tipo antártica está construida en base a mediciones en la región ártica, pero comparte muchas características en común. Estos aerosoles poseen un $PM10/I$ cercano a 3.8.

En el control de calidad de las mediciones de ECAUNGS, se encontraron 2294149 líneas de datos con valores numéricos y 958542 líneas de datos con valores fuera de los límites de detección (para el sensor de PM). Esto representa




FIG. 4: Funciones de distribución másica acumulada (concentraciones normalizadas por la densidad) para los casos de aerosoles urbanos, rurales, continentales, marinos y antárticos.

un 23.7% de la totalidad de datos que fueron eliminados de la serie. No se encontraron saltos abruptos entre los datos de PM. El análisis de calidad realizado en la base minutal y horaria no descartó ningún otro dato. Cabe aclarar que no se contaron con datos para los meses de marzo, abril y mayo de 2020.

Las tendencias horarias, mensuales y por día de la semana de las mediciones de ECAUNGS son similares en las tres fracciones tamaños de PM (denominadas PM_{1eca} , PM_{25eca} y PM_{10eca}). La Fig. 5 muestra valores mínimos de concentración en los meses cálidos y en las horas de mayor radiación solar, además de valores altos los fines de semana. Los valores medios horarios se encuentran entre 5 y $24 \mu\text{g}/\text{m}^3$ para PM_{1eca} , entre 10 y $33 \mu\text{g}/\text{m}^3$ para PM_{25eca} y entre 11 y $36 \mu\text{g}/\text{m}^3$ para PM_{10eca} . Cabe aclarar que las concentraciones mencionadas no superan los límites en la normativa vigente para provincia de Buenos Aires (DECTO-2018-1074-GDEBA-GPBA) [17]. También cabe indicar que el percentil 75 no supera los $20 \mu\text{g}/\text{m}^3$ para PM_{1eca} y se encuentra apenas por encima de ese valor para PM_{25eca} y PM_{10eca} . Estos valores bajos de PM en superficie están acordes con las características de la zona y con los resultados de las mediciones fotométricas indicadas en Scagliotti y Jorge (2020) [14], que implican una atmósfera limpia con bajas concentraciones de aerosoles en toda la columna vertical.




FIG. 5: Histograma y tendencias mensual, horaria y por día de semana de PM_{25eca} para las mediciones entre junio de 2019 y enero de 2021.

El análisis de frecuencias de la razón PM_{10}/I para ECAUNGS se muestra para la totalidad de los datos (Fig. 6), ya que no hay diferencias entre diferentes franjas horarias.

En casi todo momento, parece que las concentraciones de PM_{10eca} duplican las de PM_{1eca} , y otras pocas ocasiones las cuatriplan. Al parecer, la distribución másica por tamaño de partículas no responde a una zona urbanizada según las modelizaciones mostradas en la Fig. 4, sino que el modo principal encontrado para PM_{10}/I se corresponde principalmente con distribuciones de tipo continental y antártico.

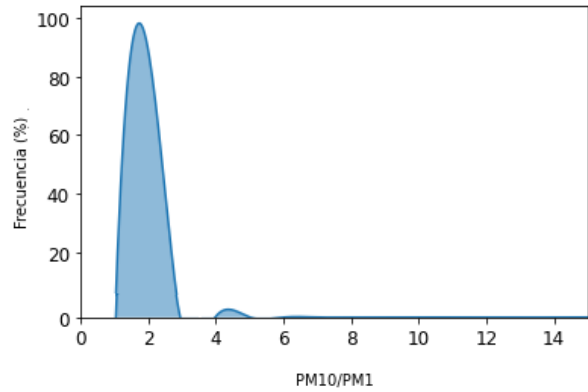


FIG. 6: Frecuencia de concentraciones de la razón de PM_{10}/I con datos de ECAUNGS.

co. Los aerosoles continentales están compuestos por productos de oxidación secundaria y partículas primarias como polvo, polen y plantas de tratamiento [11]. Mientras que el tipo antártico se origina por la neblina antártica y una leve inclusión de partículas de origen antropogénico [11]. Estos resultados concuerdan con las conclusiones expuestas en Scagliotti y Jorge (2020) [14] a partir de las mediciones fotométricas, donde se encontraron partículas gruesas y una atmósfera generalmente limpia (es decir pocos casos de contaminación urbana) con algunos casos de intrusión de aerosoles industriales, además de varios casos de aerosoles de tipo antártico. De todas formas, estos resultados deben corroborarse con mediciones validadas, ya que los LCS de PM no suelen medir directamente la fracción de PM_{10} y la informan con un mayor error [8].

El desarrollo del modelo integrador ANN con las mediciones de bajo costo de ECAUNGS y el fotómetro solar CALITOO, y con datos de ACUMAR en Dock Sud y NOAA, tiene la doble finalidad de completar el estudio en el Centro-Norte del conurbano y evaluar la calidad de los datos medidos con ECAUNGS. El mejor desempeño del modelo, que fue llamado REDungs, se consiguió practicando un filtro de medianas a PM_{25eca} (para suavizar la serie evitando valores atípicos), una normalización a las variables de tipo “mapstd” (varianza 0 y desviación estándar igual a la unidad), regla de aprendizaje de gradiente conjugado (dependiente de la derivada parcial del error respecto a los pesos $\omega_{i,k}$), función de transferencia F_k de base radial para un total de 30 neuronas ocultas y realimentación con un retraso temporal de 1 h (realimenta el modelo con la salida).

La Fig. 7 muestra la forma básica de REDungs, con los 7 predictores elegidos (valores horarios entre junio de 2019 y enero de 2021) y la realimentación de la salida a la capa oculta. El entrenamiento de REDungs se detuvo en 10 épocas, alcanzando un error RMSE (por “Root Mean Squared Error”) cercano a $0.14 \mu\text{g}/\text{m}^3$ y un R cercano a 0.99 en la validación y 0.60 en la etapa de prueba (Fig. 8). La diferencia de rendimiento entre estas etapas está vinculado a la división de los datos (60% entrenamiento, 20% validación y 20% prueba), ya que quedaron pocos para probar el modelo. En este sentido, se prefirió entrenar con mayor cantidad de información de entrada para que la red pueda converger con indicadores de buen desempeño. Aún así, to-




FIG. 7: Esquema de REDungs. Se observa la realimentación con retraso temporal de 1 h.

mando un $R = 0.6$ como el más bajo posible para REDungs, se alcanzó un desempeño muy bueno considerando los datos (en cantidad y calidad) disponibles.

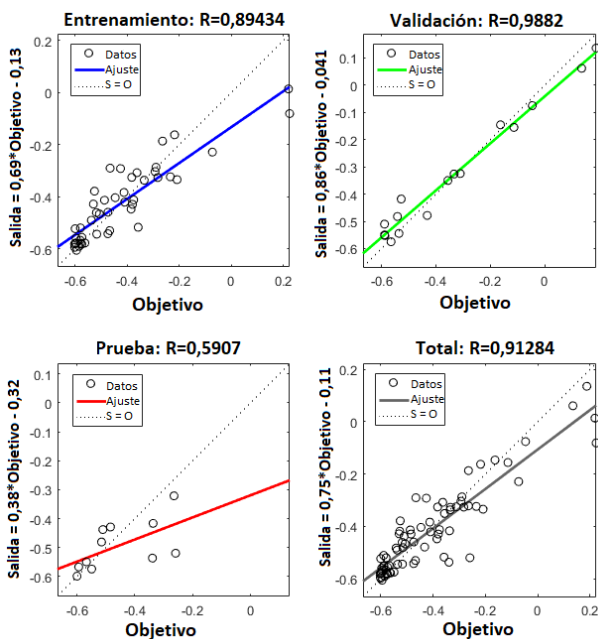


FIG. 8: Gráficas de regresión del modelo en las etapas de entrenamiento, validación y prueba.

Si bien este modelo no es suficiente para validar los datos registrados por ECAUNGS, sus indicadores alientan a considerar estas mediciones de PM como datos relativos que aportan información cualitativa valiosa sobre la CA en la zona. Se encontraron buenas correlaciones y vínculos esperados entre la meteorología, las mediciones de PM en ACUMAR y las propiedades ópticas de aerosoles en UNGS con las mediciones de PM de ECAUNGS. Con una mayor cantidad de mediciones se podrá avanzar en un modelo más robusto y completo.

El código desarrollado en lenguaje GNU OCTAVE y los

datos para el diseño y entrenamiento del modelo REDungs se puede consultar en el repositorio digital de los productos de este estudio [13].

IV. CONCLUSIONES

Con las mediciones de ECAUNGS se detectaron valores bajos de PM en relación con la radiación solar (entre el mediodía y la tarde y en los meses cálidos para la marcha anual), lo cual está vinculado a la dinámica de la capa límite (BLH). Las mediciones de ECAUNGS indican una proporción importante de la fracción gruesa de partículas ($PM_{10/1} \approx 2$) que, según las simulaciones, implican distribuciones de partículas típicas de ambientes continental y antártico. Esto último verifica los hallazgos citados a partir del estudio con las mediciones fotométricas, al igual que la baja concentración de partículas ($PM_{2,5}$ entre 10 y 33 $\mu\text{g}/\text{m}^3$).

Si bien las mediciones de ECAUNGS aun deben ser consideradas como relativas, el buen desempeño del modelo integrador REDungs ($RMSE \approx 0.14 \mu\text{g}/\text{m}^3$ y $R \approx 0.6$) indica que los valores de PM medidos se encuentran vinculados de forma lógica con la meteorología de capa límite y otras variables a nivel regional y local. Si bien no hay correlaciones lineales claras entre el AOD medido y el PM de ECAUNGS, el modelo ANN implementado logra interpretar y sacar provecho de vínculos no lineales entre estas variables. Este modelo permite actualmente conocer los valores relativos de PM de forma horaria en la zona, y su aceptable desempeño demuestra que la integración de diferentes métodos de bajo costo es posible y superadora a lo que pueda conseguirse con cada parte individual.

La predicción de PM para la zona podrá ser mejorada cuando se cuente con una mayor cantidad de mediciones, tanto en superficie (para este estudio no se contaron con mediciones entre marzo y mayo de 2020 de ECAUNGS) como fotométricas. Esto es sólo cuestión de tiempo, ya que el equipo ECAUNGS continúa en funcionamiento y las mediciones con el fotómetro solar CALITOO aún se realizan regularmente. Avanzar en este camino aportará también una mayor comprensión a la vinculación entre PM y AOD en la zona de estudio.

REFERENCIAS

- [1] Organización Mundial de la Salud. *Air pollution* [https://www.who.int/health-topics/air-pollution#tab=tab\\$_\\$1](https://www.who.int/health-topics/air-pollution#tab=tab$_$1). 2021.
- [2] Y. Rybarczyk y R. Zalakeviciute. Machine learning approaches for outdoor air quality modelling: A systematic review. *Appl. Sci.* **8**, 2570 (2018).
- [3] K. R. Kumar, Y. Yin, V. Sivakumar, N. Kang, X. Yu, Y. Diao, A. J. Adesina y R. Reddy. Aerosol climatology and discrimination of aerosol types retrieved from MODIS, MISR and OMI over Durban (29.88 S, 31.02 E), South Africa. *Atmos. Environ.* **117**, 9-18 (2015).
- [4] F. Franceschi, M. Cobo y M. Figueredo. Discovering relationships and forecasting PM10 and PM2.5 concentrations in Bogotá, Colombia, using artificial neural networks, principal component analysis, and k-means clustering. *Atmos. Pollut. Res.* **9**, 912-922 (2018).

- [5] H. Tian, P. Qiu, K. Cheng, J. Gao, L. Lu, K. Liu y X. Liu. Current status and future trends of SO₂ and NO_x pollution during the 12th FYP period in Guiyang city of China. *Atmos. Environ.* **69**, 273-280 (2013).
- [6] D. J. Lary, A. H. Alavi, A. H. Gandomi y A. L. Walker. Machine learning in geosciences and remote sensing. *Geoscience Frontiers* **7**, 3-10 (2016).
- [7] G. Miño ML & Alsina. *Diagnóstico Ambiental del Partido de San Miguel* (UNGS Ediciones, 2006).
- [8] B. Alfano, L. Barretta, A. Del Giudice, S. De Vito, G. Di Francia, E. Esposito, F. Formisano, E. Massera, M. L. Miglietta y T. Polichetti. Una revisión de los sensores de material particulado de bajo costo desde la perspectiva de los desarrolladores. *Sensores* **20**, 6819 (2020).
- [9] F. M. Bulot, S. J. Johnston, P. J. Basford, N. H. Easton, M. Apetroaie-Cristea, G. L. Foster, A. K. Morris, S. J. Cox y M. Loxham. Long-term field comparison of multiple low-cost particulate matter sensors in an outdoor urban environment. *Sci. Rep.* **9**, 1-13 (2019).
- [10] D. H. Hagan y J. H. Kroll. Assessing the accuracy of low-cost optical particle sensors using a physics-based approach. *Atmos. Meas. Tech.* **13**, 6343-6355 (2020).
- [11] J. H. Seinfeld y S. N. Pandis. *Atmospheric chemistry and physics: from air pollution to climate change* (John Wiley & Sons, 2016).
- [12] A. F. Scagliotti y G. A. Jorge. Inter-comparison of environmental low-cost sensors on Arduino platform. *Journal of the IEST* **63**, 35-45 (2020).
- [13] *Repositorio github(Scagliotti)* <https://github.com/ascaglio/Estrategias-de-bajo-costo-para-la-exploracion-de-la-calidad-del-aire.git>. 2021.
- [14] A. F. Scagliotti y G. A. Jorge. Análisis de un año de mediciones con fotómetro solar en el noroeste del conurbano bonaerense. *Anales AFA* **31**, 46-50 (2020).
- [15] Autoridad de la Cuenca Matanza-Riachuelo (ACUMAR). *Calidad de aire* <https://www.acumar.gob.ar/monitoreo-ambiental/calidad-de-aire/>. 2020.
- [16] Administración Nacional Oceánica y Atmosférica de EUA (NOAA). <https://www.ready.noaa.gov/READYcmet.php>. 2020.
- [17] *Ley ambiental Prov. Buenos Aires N.5965* <https://normas.gba.gob.ar/ar-b/decreto/2018/1074/17866>. 2020.