

AirNet: Monitoreo Predictivo de la Calidad del Aire basado en Redes Neuronales

AirNet: Predictive Air Quality Monitoring Based on Neural Networks

Juan Antonio Guerrero-Ibáñez¹, Juan José Contreras-Castillo¹, Christian Israel Ruiz Coba¹

¹Facultad de Telemática- Universidad de Colima, Avenida Universidad 333, Colonia Las Víboras, Colima, Colima, 28040. México

{antonio_guerrero, juancont}@uacol.mx

Fecha de recepción: 17 de septiembre de 2025

Fecha de aceptación: 2 de marzo de 2026

Resumen. El aire es un elemento esencial para la vida. La contaminación del aire es un serio problema para la sociedad y es causada por muchos factores y se convierte en peligrosa si excede los niveles normales de referencia. Este trabajo propone AirNet, un modelo basado en redes neuronales recurrentes convolucionales para la clasificación de los niveles de contaminación del aire para entender las condiciones de calidad del aire. Los resultados obtenidos por el modelo propuesto muestran una exactitud de 97% en la clasificación del nivel de contaminación del aire.

Palabras clave: clasificación, contaminación del aire, redes neuronales, redes neuronales convolucionales.

Summary. Air is an essential element for life. Air pollution is a serious societal problem caused by numerous factors, and it becomes hazardous when it exceeds standard reference levels. This paper proposes AirNet, a model based on convolutional recurrent neural networks, to classify air pollution levels and assess air quality conditions. The results obtained by the proposed model demonstrate 97% accuracy in classifying air pollution levels.

Keywords: classification, air pollution, neural networks, convolutional neural networks.

1 Introducción

La contaminación del aire es un problema que afecta a la mayoría de las ciudades del mundo. La Organización Mundial de la Salud (OMS) estima que el 99% de la población mundial está viviendo en lugares donde el aire supera los límites recomendados de contaminación [1]. Las principales causas de la contaminación del aire son las fábricas y el tráfico pesado. En específico, el tráfico de vehículos estáticos por un periodo prolongado de tiempo debido a congestionamiento vial. Algunos de los gases peligrosos para los seres vivos son el monóxido de carbono (CO), el dióxido de azufre (SO₂) el ozono (O₃) y dióxido de carbono (CO₂).

Todos los gases y partículas que flotan en el aire se convierten en sustancias peligrosas para los seres vivos, pudiendo ocasionar enfermedades peligrosas como cáncer de pulmón, neumonía, bronquitis, asma, entre otras. Es prioritario el monitoreo y medición constante de la presencia de sustancias peligrosas suspendidas en el aire para determinar su concentración en el aire y de esta manera poder establecer el nivel de contaminación en una cierta área de forma rápida.

Una de las tecnologías que han impulsado el monitoreo y la automatización de procesos es el Internet de las Cosas (IoT). Los sensores instalados en áreas específicas para recolectar datos de los gases y sustancias suspendidas en el aire. Todos los datos recolectados por los sensores deben ser procesados y clasificados en índices de calidad del aire [2].

El presente trabajo propone a *AirNet*, un modelo basado en redes neuronales recurrentes para clasificar los niveles de contaminación del aire. *AirNet* es parte de una arquitectura de monitoreo ambiental basada en el Internet de las Cosas y la Inteligencia artificial, la cual se denominada *ClearSky*. En este trabajo solamente se describe el diseño del modelo de clasificación.

2 Trabajos relacionados

La contaminación del aire es uno de los mayores problemas a nivel mundial y es necesaria su medición constante para identificar las condiciones ambientales que se pueden generar debido a la concentración de gases nocivos para la salud de las personas [3]. Una de las tecnologías más utilizadas para la recolección de datos relacionados con la calidad del aire es el Internet de las Cosas (IoT) [4]. Todos esos datos deben ser procesados para entender el nivel de concentración de gases nocivos en el aire. Dentro de la literatura se han propuesto varios trabajos para predecir el nivel de concentración de gases a través de técnicas de regresión. Los autores en [5] aplicaron técnicas de clasificación y regresión para predecir el índice de calidad del aire de los principales contaminantes, como PM2.5, PM10, CO, NO2, SO2 y O3, cuyos resultados mostraron que la regresión SVM (*Support Vector Machine*) fue la que obtuvo mejores resultados para predecir la calidad del aire. Otros trabajos, como el presentado en [6] han utilizado la clasificación de datos mediante el algoritmo de árbol de decisión para identificar problemas con la concentración de gases en el aire. Su evaluación mostró que su modelo alcanzó una exactitud de 85.71%, precisión de 81.82%, sensibilidad de 60.00%, y especificidad de 92.31%. Los autores en [7] compararon los métodos de clasificación SVM y *Multi-Layer Perceptron* (MLP) para identificar la calidad del aire en Yakarta. Los resultados obtenidos mostraron un mejor rendimiento de SVM. Finalmente, en [8] se realiza un estudio comparativo de tres técnicas de clasificación: *Decision Tree*, *Support Vector Machine*, y *Random Forest* (RF) para identificar el nivel de calidad del aire. Los resultados mostraron que la mejor técnica fue *Random Forest* con un valor de exactitud de 74%.

3 Propuesta de modelo

En esta sección describimos *AirNet*, un modelo basado en redes neuronales recurrentes para la clasificación de niveles de calidad del aire. Como se mencionó anteriormente, este trabajo forma parte de una plataforma tecnológica basada en IoT e Inteligencia artificial para el monitoreo de calidad del aire en zonas urbanas. Sin embargo, solo nos enfocaremos en explicar el modelo de clasificación.

3.1 Conjunto de datos

Para el presente trabajo se utilizó el conjunto de datos (*dataset*) “*Air Quality and Pollution Assessment*” [9]. El conjunto de datos se centra en la evaluación de la calidad del aire en varias regiones y contiene 5000 muestras que capturan factores demográficos y ambientales críticos que influyen en los niveles de contaminación. El *dataset* define 4 niveles de calidad del aire: *good*, *moderate*, *poor*, y *hazardous*. La figura 1 muestra una representación de algunos de los datos que incluye el conjunto de datos. Uno de los problemas que se tiene con el *dataset* es que no está balanceado, por lo que se tuvo que aplicar una técnica de sobremuestreo de minorías sintética denominada *SMOTE* (*Synthetic Minority Oversampling Technique*) para aumentar el número de registros de un conjunto de datos y obtener el balanceo del *dataset*. El *dataset* se incrementó a 8000 registros mediante esta técnica.

	Temperature	Humidity	PM2.5	PM10	NO2	SO2	CO	Proximity_to_Industrial_Areas	Population_Density	Air Quality
0	29.8	59.1	5.2	17.9	18.9	9.2	1.72	6.3	319	Moderate
1	28.3	75.6	2.3	12.2	30.8	9.7	1.64	6.0	611	Moderate
2	23.1	74.7	26.7	33.8	24.4	12.6	1.63	5.2	619	Moderate
3	27.1	39.1	6.1	6.3	13.5	5.3	1.15	11.1	551	Good
4	26.5	70.7	6.9	16.0	21.9	5.6	1.01	12.7	303	Good

Figura 1. Representación de los datos incluidos en el *dataset*.

3.2 Diseño de la red neuronal

Para este trabajo utilizamos las redes neuronales recurrentes (RNN - *Recurrent Neural Networks*). RNN son redes neuronales profundas entrenadas con datos secuenciales o series temporales para realizar predicciones basadas en entradas secuenciales. La figura 2 representa la estructura de *AirNet*. Como entrada se recibe un vector con 9 entradas que representan las características usadas para el modelo. Una capa convolucional de 64 filtros con tamaño de kernel de 3x3 y función de activación ReLU se utiliza para extraer patrones relevantes. Se definió una capa MaxPooling para reducir la cantidad de datos entre una capa y otra con el fin de agilizar el entrenamiento de la red. Se definió una capa Dropout para desactivar una fracción de neuronas durante cada iteración del entrenamiento, en nuestro caso su valor es 0.2 con el fin de evitar la dependencia de ciertos nodos y de esta forma que el modelo aprenda características más generalizadas. Se definió una capa LSTM (*Long-Short Term Memory*) para aprender dependencias a largo plazo entre pasos de tiempo de datos de series temporales y secuencias. Finalmente se definieron dos capas Densas completamente conectadas con salida de 64 y 4 unidades con el fin de realizar la clasificación del modelo.




Figura 2. Representación de la estructura de la red neuronal de AirNet.

3.3 Desarrollo del modelo

El desarrollo de *AirNet* se realizó en *Google Colaboratory*, un ambiente de desarrollo de Python gratuito basado en la nube [10]. Se utilizaron varias librerías incluyendo *TensorFlow*, *Keras*, *Pandas*, *Numpy*, *Matplotlib*. Para el entrenamiento del modelo se utilizaron 100 épocas. Se implementó la validación cruzada (*cross validation*) con el objetivo de garantizar la exactitud de las predicciones del modelo propuesto. La validación cruzada se aplica como alternativa al uso de diferentes conjuntos de datos para entrenamiento y validación. En la validación cruzada se utilizan todos los datos, por lo que se aplicó el método *k-fold cross-validation* y se definieron 5 iteraciones. Además, se implementó *early stopping* para terminar el proceso de entrenamiento si la pérdida de validación no mejora después de 10 épocas consecutivas.

4 Evaluación y resultados

En esta sección presentamos las métricas de evaluación utilizadas para medir el desempeño del modelo propuesto y discutimos los resultados obtenidos en la evaluación de *AirNet*.

4.1 Métricas de evaluación

Para la evaluación de *AirNet* se utilizaron 4 métricas claves para evaluar su desempeño. Las métricas se computarizan usando el conteo de los verdaderos positivos (TP), los falsos positivos (FP), los falsos negativos (FN) y los verdaderos negativos (TN). Las métricas usadas fueron:

- *Accuracy*: mide el rendimiento global del modelo en todas las clases y se calcula mediante la ecuación 1.
- *Precision*: cuantifica la exactitud del modelo a la hora de clasificar las muestras positivas y se calcula con la ecuación 2.

- *Recall*: evalúa la capacidad del modelo para detectar muestras positivas y se calcula mediante la ecuación 3.
- *F1 score*: representa la media de la métrica *precision* y *recall*, equilibrando ambas métricas y se calcula con la ecuación 4.

$$(1) \quad Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$(2) \quad Precision = \frac{TP}{TP + FP}$$

$$(3) \quad Recall = \frac{TP}{TP + FN}$$

$$(4) \quad F1 \text{ Score} = \frac{(Precision \times recall)}{(Precision + recall)}$$

Además se utilizó la matriz de confusión, la cual proporciona una visión general de desempeño del modelo desplegando de una forma simple los verdaderos positivos, los falsos positivos y los falsos negativos para cada una de las clases detectadas [11].

4.2 Resultados obtenidos

Lo primero que evaluamos fue el desempeño de *AirNet* durante las etapas de entrenamiento y validación. La figura 3 presenta los resultados obtenidos, donde se puede observar que *AirNet* alcanzó un valor de la métrica *accuracy* de 96% para la fase de entrenamiento y un 95% para la fase de validación. Los resultados muestran que el modelo aprendió de forma correcta, evitando el *overfitting* ya que los valores en las dos fases fueron muy similares durante todo el proceso. De igual forma se puede observar un comportamiento similar para la métrica *loss* durante las dos etapas.




Figura 3. Resultados obtenidos por *AirNet* durante las etapas de entrenamiento y validación.

La figura 4 muestra los resultados obtenidos en la evaluación *AirNet* mediante el reporte de clasificación, el cual muestra un resumen de las métricas principales para cada clase del modelo. Se observa que la precisión para cada clase fue mayor al 90% y que la exactitud total fue de 97%.

	precision	recall	f1-score	support
Good	1.00	1.00	1.00	603
Hazardous	0.96	0.97	0.97	592
Moderate	0.97	0.97	0.97	624
Poor	0.94	0.93	0.93	581
accuracy			0.97	2400
macro avg	0.97	0.97	0.97	2400
weighted avg	0.97	0.97	0.97	2400

Figura 4. Resultados obtenidos por *AirNet* mediante el reporte de clasificación.

Finalmente, la figura 5 muestra la matriz de confusión obtenida en la evaluación de *AirNet*. De acuerdo con los resultados, que la clase *Good* obtuvo valores de exactitud de 100%, mientras que dos de las clases de *AirNet* obtuvieron valores de exactitud de 97% y el resto fue de 93%. Los resultados muestran un mejor desempeño de *AirNet* con respecto a los modelos propuestos en la literatura y que fueron analizados en la sección de trabajos relacionados




Figura 5. Representación de la matriz de confusión obtenida por *AirNet* durante el proceso de evaluación.

En este trabajo proponemos *AirNet* un modelo basado en redes neuronales recurrentes convolucionales para clasificar diferentes niveles de contaminación del aire. *AirNet* mostró una exactitud en la fase de entrenamiento superior al 96% y en la fase de validación se obtuvo un resultado muy similar, lo que indica que el modelo no sufre de sobreajuste (*overfitting*) permitiendo al modelo hacer predicciones precisas a partir de nuevos datos. Mediante la matriz de confusión se demostró que el modelo es capaz de realizar clasificaciones por encima del 97% de exactitud.

Como trabajo futuro se pretende integrar *AirNet* a la plataforma tecnológica de monitoreo *ClearSky*.

5 Conclusiones y trabajo futuro

En este trabajo proponemos *AirNet* un modelo basado en redes neuronales recurrentes convolucionales para clasificar diferentes niveles de contaminación del aire. *AirNet* mostró una exactitud en la fase de entrenamiento superior al 96% y en la fase de validación se obtuvo un resultado muy similar, lo que indica que el modelo no sufre de sobreajuste (*overfitting*) permitiendo al modelo hacer predicciones precisas a partir de nuevos datos. Mediante la matriz de confusión se demostró que el modelo es capaz de realizar clasificaciones por encima del 97% de exactitud.

Como trabajo futuro se pretende integrar *AirNet* a la plataforma tecnológica de monitoreo *ClearSky*.

Referencias

- [1] Organización Mundial de la Salud, “Contaminación atmosférica”. Consultado: el 8 de marzo de 2025. [En línea]. Disponible en: <https://www.who.int/es/health-topics/air-pollution>
- [2] K. Ravindra, V. Singh, y S. Mor, “Why we should have a universal air quality index?”, *Environment International*, vol. 187, p. 108698, may 2024, doi: 10.1016/j.envint.2024.108698.
- [3] S. Dhingra, R. B. Madda, A. H. Gandomi, R. Patan, y M. Daneshmand, “Internet of Things Mobile–Air Pollution Monitoring System (IoT-Mobair)”, *IEEE Internet of Things Journal*, vol. 6, núm. 3, pp. 5577–5584, 2019, doi: 10.1109/JIOT.2019.2903821.
- [4] M. Hocine, R. Lounas, B. Mohamed Tahar, D. E. Salhi, y D. Rachid, “Air Quality Monitoring Using IoT: A Survey”, ago. 2019. doi: 10.1109/SmartIoT.2019.00028.
- [5] C. Srivastava, S. Singh, y A. P. Singh, “Estimation of Air Pollution in Delhi Using Machine Learning Techniques”, en *2018 International Conference on Computing, Power and Communication*

- Technologies (GUCON), 2018, pp. 304–309. doi: 10.1109/GUCON.2018.8675022.
- [6] B. Sugiarto y R. Sustika, “Data classification for air quality on wireless sensor network monitoring system using decision tree algorithm”, oct. 2016, pp. 172–176. doi: 10.1109/ICSTC.2016.7877369.
 - [7] S. D. Permai, N. T. M. Sagala, A. Y. Zakiyyah, H. Tanty, y J. Harefa, “Multiclass Classification for Air Quality In Jakarta Using Support Vector Machine and Multi-Layer Perceptron Classifier”, en 2022 3rd International Conference on Artificial Intelligence and Data Sciences (AiDAS), 2022, pp. 198–202. doi: 10.1109/AiDAS56890.2022.9918697.
 - [8] K. M. O. V. K. Kekulanadara, B. T. G. S. Kumara, y B. Kuhaneswaran, “Comparative Analysis of Machine Learning Algorithms for Predicting Air Quality Index”, en 2021 From Innovation To Impact (FITI), 2021, pp. 1–5. doi: 10.1109/FITI54902.2021.9833033.
 - [9] M. Mateen, “Air Quality and Pollution Assessment”. Consultado: el 8 de marzo de 2025. [En línea]. Disponible en: <https://www.kaggle.com/datasets/wisam1985/iot-agriculture-2024>
 - [10] “Google Colab”. Consultado: el 27 de agosto de 2024. [En línea]. Disponible en: <https://colab.research.google.com/#scrollTo=Wf5KrEb6vrkR>
 - [11] G. G. y A. P. J., “Identification of plant leaf diseases using a nine-layer deep convolutional neural network”, Computers & Electrical Engineering, vol. 76, pp. 323–338, jun. 2019, doi: 10.1016/j.compeleceng.2019.04.011.