

**IX SIMPOSIO “LAS CIENCIAS APLICADAS POR UN DESARROLLO SOSTENIBLE”
II TALLER DE GESTIÓN AMBIENTAL “RESILIENCIA ANTE
EL CAMBIO CLIMÁTICO”**

**Aplicación de técnicas de Inteligencia Artificial (IA) en la predicción del
comportamiento de los contaminantes atmosféricos en ambientes urbanos**

Nancy Betancourt Puebla¹, Godofredo Hernández Pérez²

¹Centro Meteorológico Provincial de Camagüey. Carretera de Nuevitas km 7^{1/2}. Camagüey, Cuba. CP 70100. MSc. (Ing. de Procesos). Especialista (Dpto. Física de la Atmósfera). e-mail: betancourt.puebla@gmail.com.

²Centro de Investigaciones de Medio Ambiente de Camagüey. Cisneros No. 105 (altos) /Pobre y Ángel. Camagüey, Cuba. CP. 70100. MSc. (Ing. de Procesos). Especialista (Dpto. Manejo de Territorio). e-mail: godofredo.hdez@gmail.com.

RESUMEN.

Alrededor del proceso de urbanización, existe una compleja problemática asociada a la contaminación ambiental y el cambio climático. A nivel mundial, la contaminación del aire ha causado afecciones de salud e incluso la muerte de miles de personas anuales, por lo cual la OMS ha indicado directrices de control. El problema se aborda actualmente bajo el marco conceptual de la sustentabilidad y la resiliencia, pues es imprescindible trazar estrategias efectivas de mitigación y adaptación.

En este sentido, modelar eficazmente el fenómeno de los contaminantes atmosféricos constituye una valiosa herramienta. Sin embargo, como dichos procesos son altamente no lineales y multifactoriales, resultan inapropiados los procedimientos que emplean ecuaciones diferenciales, puesto que estas conducen a soluciones poco realistas, lo cual implica aplicar técnicas avanzadas, fundamentalmente soportadas en la Inteligencia Artificial (IA).

Los modelos desarrollados con técnicas de IA, en especial con Redes Neuronales Artificiales (RNAs): Perceptrón Multi Capa (MLP), Perceptrón Multi Capa Cuadrática (SMLP), Redes de Base Radial (RBF), Redes Elman, posibilitan predicciones rápidas, precisas y un ajuste con pequeños márgenes de error. El objetivo del presente artículo es desarrollar una revisión bibliográfica sobre los métodos de IA utilizados para predecir el estado de la contaminación atmosférica, técnicas validadas en: partículas menores de 2.5 y 10 micras (PM_{2.5} y PM₁₀), concentración de ozono, óxidos de nitrógeno (NO_x), dióxido de nitrógeno (NO₂), permitiendo notificar alertas sobre la salud pública, gestionar mejor las políticas asociadas al cambio climático y la resiliencia urbana, el control de episodios críticos y la predicción de patrones de emisión.

Palabras clave: Contaminantes atmosféricos, resiliencia, cambio climático, Inteligencia Artificial.

ABSTRACT

Around the urbanization process, there is a complex problem associated with environmental pollution and climate change. Worldwide, air pollution has caused several health problems and the death of thousands of people every year, for that reason the OMS has indicated

control guidelines. The problem is currently being addressed under the conceptual framework of sustainability and resilience, since it is essential to draw effective mitigation and adaptation strategies.

In this sense, effectively modeling the phenomenon of atmospheric pollutants constitutes a valuable tool. However, as these processes are highly non-linear and multifactorial, procedures that use differential equations are inappropriate, since they lead to unrealistic solutions, which implies applying advanced techniques, fundamentally supported by Artificial Intelligence (AI).

The models developed with Artificial Intelligence techniques, especially with Artificial Neural Networks (ANNs): Multi Layer Perceptron (MLP), Quadratic Multi Layer Perceptron (SMLP), Radial Base Networks (RBF), Elman Networks, allow fast, accurate and a setting with small margins of error. The objective of this article is to develop a review on the AI methods used to predict the state of atmospheric pollution, techniques validated in: particles smaller than 2.5 and 10 microns ($PM_{2.5}$ and PM_{10}), ozone concentration, oxides of nitrogen (NO_x), nitrogen dioxide (NO_2), allowing the notification of public health alerts, better management of policies associated with climate change and urban resilience, the control of critical episodes and the prediction of emission patterns.

Keywords: Contaminantes atmosféricos, resiliencia, cambio climático, Inteligencia Artificial.

INTRODUCCIÓN.

Actualmente se plantea que el efecto invernadero es el resultado de la emisión descontrolada, por el hombre, de gases reconocidos con este efecto por el Panel Intergubernamental para el Cambio Climático (IPCC): metano (CH_4), óxido nitroso (N_2O) y dióxido de carbono (CO_2), lo cual produce incrementos en la temperatura ambiente y con ello la afectación parcial o total de los ecosistemas. De acuerdo con Morales, 2006 (como se citó en Sánchez et al., 2014) las causas antropogénicas de la contaminación ambiental del aire son: la producción industrial, el uso de la tierra, las esferas del transporte y los servicios, entre otras, casi todas interrelacionadas con la utilización de combustibles fósiles. O sea, la contaminación atmosférica y el cambio climático no deben de ser tratados como problemas distintos, dado que ambos eventos se encuentran estrechamente relacionados. Además, la contaminación del aire ha causado diversas afecciones de salud, situación que se vería agravada como consecuencia de lo anterior.

La contaminación atmosférica, según Wark y Warner, 2002 (como se citó en Sánchez et al., 2014) se define como la presencia en la atmósfera de uno o más contaminantes o sus combinaciones, en cantidades tales y con tal duración, que puedan afectar la vida humana o que puedan ser perjudiciales para la vida vegetal, animal o del ambiente, de modo que interfieran en el goce de la vida, la propiedad o el ejercicio de las actividades.

En relación con las fuentes de contaminación según Ballester, 2005 (como se citó en Sánchez et al., 2014), en la atmósfera urbana, normalmente provienen de fuentes móviles y fijas de combustión y se dividen en fuentes puntuales, de área y naturales, esta última referida a la actividad volcánica, tormentas de polvo, y otros procesos como las emisiones biogénicas derivadas de la descomposición de la materia orgánica por vía microbiana. A su vez, dentro de las fuentes fijas se encuentran las fuentes puntuales y de área; una fuente puntual o estacionaria se refiere a cualquier instalación fija que realiza operaciones o

procesos derivados de la actividad industrial y que liberan a la atmósfera emisiones producto, fundamentalmente, de las operaciones de combustión. Los principales contaminantes asociados a la combustión son: Dióxido de azufre (SO₂), óxidos de nitrógeno (NO_x), dióxido de carbono (CO₂), monóxido de carbono (CO), hidrocarburos aromáticos policíclicos (HAPs) y partículas en suspensión (PM).

Por su parte, una fuente de área son emisiones que no se localizan en un punto específico dado que se generan en una serie de fuentes fijas pero pequeñas, numerosas y dispersas, que en conjunto pueden afectar la calidad del aire en una región. En este tipo de fuentes se incluyen caminos, plantas de tratamiento de residuales, combustión doméstica, quemas agrícolas e incendios forestales.

Dentro de las fuentes móviles se incluyen diversas formas de transporte y equipos o maquinarias no fijas que emplean motores de combustión con la utilización de combustibles fósiles. Estos equipos, según plantean Aragón, 2011 y Cárdenas et al., 2003 (como se citó en Sánchez et al., 2014) son los responsables de las emisiones de Dióxido de azufre (SO₂), óxidos de nitrógeno (NO_x), monóxido de carbono (CO) y compuestos orgánicos volátiles (COV).

Los contaminantes atmosféricos, de acuerdo con Ballester, 2005 (como se citó en Sánchez et al., 2014) se distinguen en primarios y secundarios. Los primeros proceden directamente de las fuentes de emisión y los secundarios se generan producto a reacciones y transformaciones químicas y físicas que sufren los contaminantes primarios en el seno de la atmósfera y donde tienen un papel preponderante las reacciones fotoquímicas y la acidificación del medio. También, las emisiones de gases y aerosoles contaminantes y su posterior evolución e interacción con el entorno dependen de varios factores como la hora del día, la temporada del año, la ubicación geográfica, todo lo cual influye en la intensidad de las reacciones fotoquímicas generadoras de contaminantes secundarios, además de que poseen incidencia en el grado de dispersión de los contaminantes la presencia de objetos geográficos como cuencas y valles los cuales pueden inhibir o contrariamente facilitar la dispersión de la contaminación y donde frecuentemente se origina uno de los fenómenos de mayor importancia en este sentido, o sea, las inversiones térmicas las cuales atrapan a las sustancias nocivas cerca de la superficie lo que hace extremadamente peligrosa la exposición a las mismas por el efecto de incremento en su concentración y por lo cual han existido episodios críticos sobre la salud humana en varios países. En general, los efectos de los contaminantes atmosféricos sobre la salud humana, según alerta la Organización Mundial de la Salud (OMS) son:

Efectos a corto plazo: dolor de cabeza, irritación de los ojos, irritación de la piel, dolor de garganta, neumonía y bronquitis.

Efectos a largo plazo: enfermedades respiratorias, efectos en el sistema nervioso central, enfermedades hepáticas, enfermedades cardiovasculares, consecuencias en el embarazo.

El problema de la contaminación atmosférica se aborda actualmente bajo el marco conceptual de la sustentabilidad y la resiliencia, a través del concepto de sistemas socio-ecológicos, esto es, el resultado del acoplamiento de un sistema social y uno ambiental y donde es importante considerar cinco dimensiones básicas: social, ecológica, económica, física e institucional (GIZ, 2014). Además, se requiere: establecer sistemas de monitoreo, de predicción y de alerta, con información meteorológica, de calidad del aire, de salud y

sociodemográfica. Las sinergias que se producen bajo esta óptica permiten que las ciudades sean más inclusivas, seguras, resilientes y sostenibles.

En este sentido, el Programa Perfiles de Ciudades Resilientes lanzado por la ONU (Programa de las Naciones Unidas para los Asentamientos Humanos, 2017), tiene por fin apoyar a los gobiernos locales en el desarrollo de capacidades que permitan mejorar la resiliencia. En dicho perfil se consideran aspectos básicos, dentro de ellos:

- Gestionar la organización y coordinación para comprender y reducir el riesgo de desastres, sobre la base de la participación de grupos de ciudadanos.
- Mantener actualizada la información sobre peligros y vulnerabilidades, evaluaciones de riesgos y contemplarlas en los planes de desarrollo urbano.
- Instalar en la ciudad sistemas de alerta temprana y capacidades en gestión de emergencias.

En Cuba, además, en los objetivos de la Agenda al 2030 de la ONU para el Desarrollo Sostenible, se trabaja en: ODS 11: “Lograr que las ciudades y los asentamientos humanos sean inclusivos, seguros, resilientes y sostenibles” y “De aquí a 2030, reducir el impacto ambiental negativo per cápita de las ciudades, incluso prestando especial atención a la calidad del aire y la gestión de los desechos municipales y de otro tipo”.

Debe señalarse, según indica Cortina (2012) que las necesidades fundamentales ante los posibles efectos de la contaminación atmosférica relacionados con el campo climático, se centran en:

- Establecer sistemas de vigilancia y monitoreo que incluyan información meteorológica, de calidad del aire, de salud y sociodemográfica, con el objetivo de detectar cambios tempranos y poder obtener datos para otros estudios.
- Realizar estudios epidemiológicos para valorar el impacto del ozono, material particulado y otros contaminantes relacionados con la variabilidad climática y sus tendencias sobre la salud humana y los diferentes ecosistemas.
- Desarrollar modelos para la predicción de los posibles efectos en la salud de los cambios previstos en cuanto al clima y la calidad del aire, donde dichos modelos deberían incluir previsiones en cuanto a las tendencias futuras en contaminación atmosférica, cambios en las características de la población y variaciones en los fenómenos meteorológicos y climáticos. Estas predicciones deben de ser validadas de manera continuada, mediante su confrontación con los datos del sistema de vigilancia.

La predicción es una actividad esencial cuya importancia se ha incrementado en las últimas décadas, convirtiéndose en imprescindible en la gran mayoría de los procesos de toma de decisiones. Por tanto, el pronóstico de manera efectiva, constituye una potente herramienta de análisis con un amplio espectro de aplicación. En el caso específico de la contaminación atmosférica, la predicción abarca desde: la evaluación de estrategias de control de emisiones y su impacto en la calidad del aire, el soporte en la toma de decisiones de carácter ambiental con el objetivo de trazar estrategias de mitigación y control, hasta la resiliencia ante sus efectos; además de la generación de información valiosa para comprender y establecer la dinámica de la atmósfera y la contaminación en un lugar o región determinada (Herrera, 2019).

Sin embargo, el modelado de los procesos de dispersión de contaminantes es complejo y depende de factores no lineales por lo que a menudo se requiere aplicar técnicas avanzadas como las derivadas de la IA. Por ejemplo, un factor clave de acuerdo con Ramos y Hernández, 2014 (como se citó en Sánchez et al., 2014) para predecir la dispersión de los contaminantes en la atmósfera es conocer en cada momento el estado de los flujos y dirección del viento en los niveles bajos de la tropósfera. En este aspecto, efectuar extrapolaciones a partir de modelos estadísticos puede conducir a errores significativos en la predicción, sin embargo, la aplicación de técnicas de IA como redes neuronales y las cadenas de Markov, han resultado de gran utilidad en este sentido.

DESARROLLO.

¿La Inteligencia Artificial podría ayudar a enfrentar los retos globales referentes a la contaminación atmosférica y el cambio climático?

Para el desarrollo del presente artículo se realizó una investigación de tipo descriptiva con análisis documental, para la recopilación bibliográfica y la revisión de la literatura. Se utilizaron como criterios de búsqueda las palabras clave: contaminantes atmosféricos, resiliencia urbana, cambio climático, pronóstico, Inteligencia Artificial (métodos, técnicas y herramientas de IA).

La búsqueda se encaminó a obtener artículos publicados en el periodo comprendido entre: 2000-2021, escritos en Español e Inglés en las siguientes bases de datos:

1. Scielo: <http://www.scielo.org/php/index.php>
2. Science Direct: <https://www.sciencedirect.com/>
3. Elsevier: <https://www.elsevier.com/about/open-science>
4. Springer: <http://www.springer.com/gp/>
5. Scopus: <http://www.scopus.com/>
6. Dialnet: <https://www.dialnet.uniroja.es/>

Del conjunto de resultados se optó por seleccionar aquellas publicaciones que se relacionaron de forma directa al tema de la contaminación atmosférica y sus efectos en el cambio climático, así como la vigilancia y pronóstico de la calidad del aire mediante métodos y técnicas de IA, como una de las vías fundamentales para la mitigación y resiliencia antes dichos fenómenos.

La Inteligencia Artificial (IA) como herramienta emergente.

La Inteligencia Artificial (IA), según la definición dada por la Organización para la Cooperación y el Desarrollo Económicos, OECD (2019) es:

“Un sistema basado en máquinas que puede, para un conjunto determinado de objetivos definidos por el ser humano, hacer predicciones, recomendaciones o tomar decisiones que influyen en entornos reales o virtuales. Los sistemas de IA están diseñados para funcionar con diversos niveles de autonomía. Además, la IA son máquinas que realizan funciones cognitivas similares a las de los humanos”.

Actualmente, para la obtención de modelos de pronósticos de contaminantes atmosféricos existen diversos métodos que se resumen en “*Métodos de caja blanca*” y “*Métodos de caja negra*”. En el primer grupo se encuentran los métodos de caja blanca: Métodos Físico - matemáticos y Estadísticos. Dentro de los métodos de caja negra (derivados de la IA) se aplican: Redes Neuronales Artificiales (RNAs), lógica difusa o borrosa, Sistemas de

Inferencia Adaptativo Neuro-Difuso, Máquinas de Soporte Vectorial (MSV), Árboles de decisión, Sistemas expertos, Redes Bayesianas, Redes Bayesianas Dinámicas, Redes de Markov.

A su vez, para los métodos de *caja negra* se adoptó la clasificación existente de acuerdo a la forma en que las IA ejecutan la representación del conocimiento:

Métodos simbólicos: Dirigidos a resolver problemas definidos con una representación simbólica, al permitir que un algoritmo sea capaz de operar sobre ella y a la vez generarla como solución, por lo que se fundamentan en técnicas asociadas a mecanismos con capacidad de inferir soluciones y nuevos conocimientos a partir del conocimiento representado.

Métodos Conexionistas: Pueden caracterizar la representación y la adquisición del conocimiento y técnicas de aprendizaje a partir del conocimiento empírico.

Métodos Híbridos: Combinación de diferentes métodos predictivos, que se utilizan con el objetivo de lograr un pronóstico más robusto.

Por su parte, Mora-Flores (2005) indica varias referencias en las cuales se describe un conjunto de técnicas que utilizan la IA, dentro de ellas se encuentran:

a) Árboles de decisión.

Diagrama que representa en forma secuencial un conjunto de condiciones y acciones para representar la relación existente entre cada condición y el grupo de acciones permisibles. Dada la necesidad de describir condiciones y acciones, permite identificar las decisiones que deben tomarse de manera formal.

b) Sistemas expertos.

Intentan razonar como un experto humano, con ventajas asociadas de aumento de productividad, ahorro de tiempo y dinero y conservación de conocimientos. Su característica fundamental es que separa los conocimientos almacenados (base de conocimiento) del programa que los controla (motor de inferencia); los datos de determinado problema se almacenan en espacio físico independiente (base de datos).

c) Lógica Difusa.

Estos sistemas obtienen una salida en función de sus entradas, sin necesidad de un modelo analítico. Un sistema difuso es un SBC estructurado como un conjunto de reglas simbólicas del tipo “sí-entonces”, que usan el lenguaje natural para representar la información. Desde el punto de vista matemático, es un sistema determinista y proporciona un mapeado no-lineal entre entradas y salidas.

d) Sistema basado en casos.

Los sistemas de razonamiento basado en casos CBR (del inglés Case-Based Reasoning) resuelven problemas a partir de otros similares denominados “casos”. Utilizan conocimiento específico de experiencias previas para resolver un problema, buscando casos con valores similares de las características que lo identifican, donde el aprendizaje requiere de métodos para seleccionar el conocimiento relevante de la experiencia, integrar el caso en la estructura del conocimiento e indexar el problema para ser seleccionado en situaciones similares.

e) Agentes inteligentes de software.

Un Agente es un sistema computacional que es capaz de realizar acciones en forma independiente para beneficio de su usuario o dueño (ideando lo que necesita ser hecho para

satisfacer sus objetivos de diseño, en lugar de que constantemente se le esté diciendo que hacer paso a paso). El principal punto acerca de los Agentes es que son autónomos: capaces de actuar independientemente, teniendo control de su propio estado interno.

f) Redes neuronales (RNAs).

Es el método conexionista por excelencia y permite la solución de problemas complejos, como la evolución de una base de conocimientos que se actualizan con cada ejemplo. Las redes neuronales son combinaciones de elementos simples de procesos interconectados que operan de forma paralela para resolver problemas relacionados con el reconocimiento de formas o patrones, predicción, codificación, control y optimización, entre otras aplicaciones.

g) Sistemas híbridos inteligentes.

Para la solución de problemas reales, la mayoría de investigaciones han demostrado que se obtienen mejores respuestas ante un problema específico mediante la unión de algunas de estas técnicas en lo que se conoce como “sistemas híbridos”.

Uno de los aspectos más importantes en el diseño de un sistema de este tipo es la complementación de los dos tipos de conocimiento (teórico y empírico) disponibles cuando se aborda un problema. Existen varias combinaciones entre los métodos; su utilización puede tener muchas ventajas, entre ellas:

- La integración de dos técnicas complementarias permite que una supla las deficiencias de la otra, de forma que pueda obtenerse un mejor desempeño.
- El uso de diferentes técnicas de representación del conocimiento amplía la capacidad del sistema para recibir nueva información; un solo método aumenta las imposiciones y restringe el sistema, dificultando la solución del problema.
- Algunos sistemas complejos que no pueden ser tratados empleando una sola técnica pueden ser divididos en subproblemas para su solución y luego tratarlos como un todo para obtener una solución global óptima del problema analizado.
- El procesamiento de la información de diferentes módulos en paralelo permite diseñar un sistema con mayor desempeño, más robusto y con una mayor tolerancia a fallos.

En síntesis, con la utilización de sistemas híbridos, esto es, con la integración de varios módulos que cooperan entre sí, cada uno con especificaciones particulares, se busca mejorar el tratamiento para alcanzar un objetivo común o solucionar un problema.

La inteligencia artificial (IA) en la predicción de la contaminación atmosférica.

Dentro de estas técnicas se tienen varias que han sido aplicadas con mayor frecuencia en la predicción de los contaminantes atmosféricos, existiendo a su vez sub clasificaciones en relación con las características específicas que adoptan las mismas en la medida que han evolucionado en el tiempo como producto de la investigación en este campo, por ejemplo, el empleo en el dominio de las redes neuronales los diseños de arquitecturas con varias capas de neuronas. Una descripción de las técnicas más utilizadas se muestra a continuación:

• **Perceptrón Multi Capa (MLP).**

Es una red relativamente sencilla de usar, sin recurrencias y con un eficiente algoritmo de retropropagación. Posee elevada capacidad de generalización y robustez, que minimiza la desventaja del considerable tiempo de entrenamiento que se requiere, no obstante, este tiempo se incrementa conforme a la complejidad de la estructura de datos a modelar, como sucede en los modelos de calidad del aire.

• **Perceptrón Multi Capa Cuadrática (SMLP).**

Creada por G.W. Flake (1998) quien la denominó, “Squared Unit Augmented, Radially Extended, Multi Layer Perceptron” ó SMLP, este último término se utiliza más en la literatura. Es una red híbrida que usa características de entradas lineales y no lineales resultantes de la expansión de la Distancia Euclidiana alrededor de un centro en un grupo de datos.

- **Redes de Base Radial (RBF).**

A diferencia del Perceptrón Multicapa (MLP), las (RBF) son arquitecturas que disponen siempre de tres capas: capa de entrada, capa oculta y capa de salida. Tiene la característica de que cada neurona de la capa oculta se activa con una función radial que define un centro para cada neurona de la capa oculta.

- **Redes Elman.**

Estas redes a diferencia de otras arquitecturas, son parcialmente recurrentes, por lo que presentan algunas conexiones hacia atrás. Algunas neuronas de entrada son utilizadas para recoger la información de la que disponían otras neuronas en el instante anterior. Llamadas también neuronas de contexto, dado que hace referencia al estado anterior de la red. Se realimentan las salidas de las neuronas de la última capa oculta de modo que, en cierto sentido, la red dispone de información acerca de la entrada del instante anterior.

- **Algoritmo de aprendizaje para el análisis de datos multivariantes–LAMDA.**

Algoritmo de clasificación multivariable que combina la capacidad de generalización de la lógica difusa y la capacidad de interpolación de los conectores de lógica híbrida. Puede realizar aprendizaje supervisado y no supervisado, y es de fácil implementación. La estructura del clasificador es similar a la de una red neuronal; requiere de una etapa de entrenamiento en la cual se crean y modifican las clases, y una etapa de reconocimiento de patrones para la asignación de individuos a clases fijas.

- **Máquinas de Soporte Vectorial (MSV).**

Su enfoque es sistemático y respaldado por teorías de aprendizaje estadístico; son un algoritmo de estimación (learning machine) basado en procedimientos de estimación de parámetros a partir de un conjunto de datos (training), el cálculo del valor de la función (testing) y la evaluación de la precisión (performance).

- **Redes Bayesianas.**

Son una representación gráfica de dependencias para razonamiento probabilístico. También conocidas como red probabilística, red causal o mapa de conocimiento.

Se conforman a partir de un grafo dirigido acíclico conexo más una distribución de probabilidad sobre sus variables.

- **Redes Bayesianas dinámicas.**

Representan procesos dinámicos. Consisten en una representación de los estados del proceso en un tiempo (red estática) y las relaciones temporales entre dichos procesos (red de transición). Se pueden ver como una generalización de las cadenas (ocultas) de Markov.

- **Redes (cadenas) de Markov.**

Una cadena de Markov representa un proceso estocástico en torno a un conjunto de estados que varían en el tiempo, siendo cada cambio una transición del sistema. Aunque los cambios no están predeterminados, las probabilidades del próximo estado en función del estado anterior son conocidas y estas son constantes a lo largo del tiempo.

- **Sistemas Adaptativo Neuro-Difuso.**

Constituye uno de los métodos híbridos más utilizados. Es un algoritmo de aprendizaje y clasificación multivariable que combina las capacidades de generalización de la lógica

difusa y de interpolación de los conectores de lógica híbrida. La estructura del clasificador es similar a la de una red neuronal; requiere de una etapa de entrenamiento para crear y modificar las clases, y otra de reconocimiento de patrones para la asignación de individuos a clases fijas.

ANÁLISIS DE LAS REFERENCIAS.

Actualmente existe consenso en la comunidad científica internacional en que producto a causas antropogénicas, se liberan al aire gases, partículas y aerosoles contaminantes. Estas emisiones, como ha sido reconocido por la OMS, afectan la salud humana y de los ecosistemas y además constituyen un factor desfavorable que potencia los efectos sobre el cambio climático. La situación adquiere mayor complejidad porque los problemas de calidad del aire son el resultado de las interacciones y sinergias entre fuerzas motrices o estructurales que incluyen: crecimiento demográfico, modelo de desarrollo económico, patrones de movilidad, producción, consumo, intensidad y eficiencia en el uso de combustibles fósiles, entre otros. Comprender, por tanto, la ciudad como un sistema socio-ecológico, es vital para lograr reducir la vulnerabilidad antes estos factores, y alcanzar la resiliencia y la sustentabilidad. Por ello, la aplicación de una técnica dada no es garantía suficiente para obtener resultados satisfactorios, se requiere de la implementación de estrategias que consideren todas las dimensiones del socioecosistema: Social, ecológica, económica, física e institucional.

Por otra parte, los modelos desarrollados con técnicas de IA, permiten predecir el estado de la contaminación atmosférica de forma rápida, precisa y con pequeños márgenes de error, lo cual permite notificar alertas sobre la salud pública, gestionar mejor las políticas asociadas al cambio climático y la resiliencia urbana, el control de episodios críticos y la predicción de patrones de emisión. O sea, constituyen una herramienta eficaz que ha sido utilizada con éxito para estos objetivos.





Algunos resultados en la aplicación de las técnicas de IA, así como híbridas en la predicción de la contaminación atmosférica encontrados en esta investigación bibliográfica son:

- Ando et al. (2000) estimaron los niveles de CO y SO₂ en la ciudad de Catania, Italia utilizando una (MLP) y el método de optimización de mínimos cuadrados, obtuvo los mejores resultados con la red (MLP).
- Nagendra et al. (2005) implementaron una MLP para predecir el promedio de CO en Delhi, India. Obtuvieron mejores resultados con redes entrenadas con variables meteorológicas y características del tráfico.
- Aguirre et. al. (2006) compararon modelos MLP y un modelo de regresión lineal, para predecir niveles de O₃ y NO₂ en tiempo real en Bilbao, España. Los resultados mostraron que las MLPs realizan mejor predicción que los modelos de regresión.
- Salini et al. (2006) diseñaron una RNA para predecir la concentración de PM_{2.5} en Santiago de Chile. Obtuvieron que la MLP tuvo mejor desempeño en la predicción que el perceptrón simple y que el modelo de persistencia.
- Brunelli et al. (2007) predijeron la máxima concentración para SO₂, O₃, PM₁₀, NO₂ y CO, en Palermo, Italia.
- Díaz, S. (2014) aplicó un sistema integral de minería de datos y redes neuronales para la predicción y control de la contaminación por PM₁₀ en la ciudad de Chimbote, Perú,

haciendo uso del Perceptrón Multicapa con lo que logró realizar predicciones de calidad del aire en tiempo real y analizar el impacto en la salud de la población.

- Anaya, J. J. (2015) diseñó y aplicó con éxito un sistema prototipo para la estimación del comportamiento del índice de calidad del aire usando técnicas de aprendizaje computacional.
- Lozada, R. (2017) realizó el diseño y simulación de un sistema de pronóstico de precipitación pluvial utilizando técnicas neuro-difusas y demostró que las mismas son aplicables para el pronóstico de la precipitación pluvial.
- Rodríguez, A. (2018) modeló con grado de precisión adecuado el diagnóstico de la calidad del aire, a escala local, para concentraciones de contaminantes generadores de lluvia ácida y para investigar los efectos de las partículas en la salud humana, mediante un modelo híbrido basado en PSO-SVM con una función de núcleo o 'kernel' RBF.
- Cabrera – Hernández et al. (2019) lograron optimizar en Ciudad México el modelo generado por ANFIS (Adaptive neuro fuzzy inference system) para partículas PM₁₀ contaminantes utilizando algoritmos de inteligencia de enjambre (sistema multiagentes).
- Mestizo et al. (2020) aplicaron con éxito redes bayesianas para la predicción de los límites máximos de las concentraciones promedio de PM_{2.5} establecidos por la Organización Mundial de la Salud (OMS) en la ciudad de Xalapa, Veracruz, México.
- Chaparro, L. V. (2021) evaluó una red neuronal recurrente para predicción de riesgo por SO_x en la ciudad de Bogotá.

Luego de un análisis elemental de las referencias, se obtuvieron los siguientes resultados:



CONCLUSIONES.

1. Existe un problema real en torno a la contaminación atmosférica en las ciudades, tanto por causas antropogénicas, como derivadas de los efectos del cambio climático.
2. Dada la interacción mutua entre ambos factores y su efecto nocivo sobre la salud humana y los ecosistemas, este fenómeno, debe abordarse desde el marco conceptual de la sustentabilidad y la resiliencia.
3. Es necesario disponer de herramientas que permitan notificar alertas sobre la salud pública, gestionar con mayor efectividad las políticas asociadas al cambio climático y la resiliencia urbana, el control de episodios críticos, así como para la predicción de patrones de emisión.
4. Existe una tendencia creciente hacia la utilización de técnicas para el modelado de la contaminación atmosférica que utilizan la IA, independientemente de que los modelos físico-matemáticos y estadísticos se emplean con éxito en problemas específicos. Estos últimos, incluso pueden trabajar en cooperación con las técnicas de IA.
5. Dentro de las técnicas de IA, las RNAs y las de machine – learning, han tenido un desempeño preponderante en la predicción de la contaminación atmosférica.

REFERENCIAS BIBLIOGRÁFICAS.

Aguirre – Basurko E., Ibarra- Berastegib G., and Madariagac I. (2006). Regression and multilayer perceptron-based models to forecast hourly O₃ and NO₂ levels in the Bilbao area. *Environmental Modelling and Software*, 21(4):430 – 446. http://www.researchgate.net/publication/222420386_Regression_and_multilayer_perceptron_based_models_to_forecast_hourly_O3_and_NO2_levels_in_the_Bilbao_area

Ahrens, C. D. (2009). *Meteorology today* (9na ed.). Brooks/Cole, 549 pp (como se citó en Servicio de Evaluación Ambiental (SEA), Chile. (2012). *Guía para el Uso de Modelos de Calidad del Aire*. <http://www.nanopdf.com>

Anaya, J. J. (2015). Sistema prototipo para la estimación del comportamiento del índice de calidad del aire usando técnicas de aprendizaje computacional. [Tesis de Maestría, Universidad Nacional de Colombia]. Archivo digital. <http://www.repositorio.unal.edu.co>

Ando B., Baglio S., Graziani S., and Pitrone N. (2000). Models for air quality management and assessment. *System, Man, and Cybernetics, Part C: Applications and Reviews*, IEEE Transactions on, (30)3:358–363. http://www.researchgate.net/publication/324455263_Air_Quality_Monitoring_Using_Model_A_Review

Aráquez E, Ordóñez J.M., Serrano J., Aragonés N., Fernández-Patier R., Gandarillas A., and Galán I (1999). Contaminantes atmosféricos y su vigilancia. *Revista Española de Salud Pública*, 73(2):123-132 (como se citó en Cortina, M.G., 2012). Aplicación de técnicas de inteligencia artificial a la predicción de contaminantes atmosféricos. [Tesis Doctoral, Universidad Politécnica de Madrid]. Archivo digital: <http://www.scielo.isciii.es>

Basogain, X. (s.f.). *Redes neuronales artificiales y sus aplicaciones*. [Curso]. Escuela Superior de Ingeniería de Bilbao, EHU. <http://www.ocw.ehu.eus>

Béné, C., Wood, R.G., Newsham, A. & Davies, M. (2012). Resilience: New Utopia or New Tyranny? Reflection About the Potentials and Limits of the Concept of Resilience in Relation to Vulnerability Reduction Programmes, Documentos de trabajo del IDS, No. 405, disponible en <https://www.ids.ac.uk/files/dmfile/Wp405.pdf>

Brunelli U., Piazza V., Pignato L., Sorbello F., and Vitabile S. (2007). Two-days ahead prediction of daily maximum concentrations of SO₂, O₃, PM₁₀, NO₂, CO, in the urban area of Palermo, Italy. Atmospheric Environment, 41(14):2967-2995. <http://www.sciencedirect.com> <http://doi.org/10.1016/j.atmosenv.2006.12.013>

Cabrera-Hernández, M., Ramírez-Montañez, J., Aceves-Fernández, M., Pedraza-Ortega, J., Ramos-Arreguin, J. (2019). Propuesta de mejora de modelado de partículas contaminantes PM₁₀ mediante algoritmos de inteligencia colectiva de bacteria BFOA Research in Computing Science 148(8). <http://www.rcs.cic.ipn.mx>

Calzada, A. L. (2018). Aplicación de minería de datos para la predicción de alertas por NO₂ en Madrid. [Tesis de Maestría, Universidad Complutense Madrid]. Archivo digital. <http://www.eprints.ucm.es>

Castillo, E., Gutiérrez, J.M, Hadi, A.S. (1996). Sistemas Expertos y Modelos de Redes Probabilísticas. Universidad de Cantabria, España. Universidad de Cornell, USA. <http://www.documat.unirioja.es>

Cevallos, A.J. (2008). Redes Neuronales de Base Radial aplicadas a la mejora de la calidad. Industrial Data, 11(2): 63-72. <http://www.redalyc.org/articulo.oa?id=81619819009>

Chaparro, L. V. (2021). Evaluación de red neuronal recurrente para predicción de riesgo por SO_x en la ciudad de Bogotá. [Tesis de Grado, Universidad Sergio Arboleda]. Archivo digital. <http://www.researchgate.net>

Checa, A. (2019). Desarrollo de un modelo basado en redes neuronales artificiales para la predicción de emisiones contaminantes en un motor diesel di. [Tesis de Grado, Universidad Politécnica de Valencia]. Archivo digital. <http://www.riunet.upc.es>

Clean Air Institute, Universidad Pontificia Bolivariana. (2017). Plan integral de gestión de la calidad del aire para el Área Metropolitana del valle de Aburrá, PIGECA 2017-2030. <http://www.car.gov.co>

Cortina, M.G. (2012). Aplicación de técnicas de inteligencia artificial a la predicción de contaminantes atmosféricos. [Tesis Doctoral, Universidad Politécnica de Madrid]. Archivo digital: <http://www.scielo.isciii.es>

Cuervo, E. (2019). Control, análisis y predicción de la calidad del aire en Valladolid mediante tecnología Big Data. [Tesis de Maestría, Universidad de Valladolid]. Archivo digital. <http://www.uvadoc.uva.es>

Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ). (2014). Vulnerability Assessments: A Sourcebook – Concept and Guidelines for Standardized Vulnerability Assessments, disponible en https://gc21.giz.de/ibt/var/app/wp342deP/1443/wpcontent/uploads/filebase/va/vulnerability_guidesmanualsreports/Vulnerability_Sourcebook_Guidelines_for_Assessments_-_GIZ_2014.pdf

Díaz, S. (2014). Sistema integral bajo el enfoque de minería de datos y redes neuronales para la predicción y control de la contaminación atmosférica por PM₁₀ en la ciudad de Chimbote. [Tesis Doctoral, Universidad Nacional del Santa, Perú]. Archivo digital. <http://www.repositorio.uns.edu.pe>

Domínguez-Guevara, R., Cabrera-Hernández, M., Aceves-Fernández, M. A., Pedraza-Ortega, J. C. (2019). Propuesta de red neuronal convolutiva para la predicción de partículas contaminantes PM₁₀. *Research in Computing Science* 148(7): 51-63. <http://www.rcs.cic.ipn.mx>

Garrido L. (2006). Agentes inteligentes y sistemas multiagentes. [Tutorial]. Instituto Tecnológico de Monterrey. <http://www-csi.mtv.itesm.mx/lgarrido>

Herrera, J. (2019). Redes neuronales para predicción de contaminación del aire en Carabayllo-Lima. [Tesis de Maestría, Universidad Nacional Federico Villarreal]. <http://repositorio.unfv.edu.pe/handle/UNFV/3428>

Hurtado J.P. (2014). Lógica difusa: perspectiva y aplicaciones. Universidad del Quindío, Armenia. <http://www.bdigital.uniquindio.edu.co>

Lino-Ramírez, C., Bautista-Sánchez, R., Bombela-Jiménez, S. P. (2019). Utilización de un sistema en tiempo real para la predicción de contaminación del aire. *Research in Computing Science* 148(7): 441-453. Archivo digital. <http://www.rcs.cic.ipn.mx>

Lozada Vilca, R. (2017). Redes neuronales y lógica difusa aplicado a un sistema climatológico. [Tesis Doctoral, Universidad Nacional de San Agustín]. Archivo digital. <http://repositorio.unsa.edu.pe/handle/UNSA/5040>

Martín, E. (2019). Aplicación de modelos de redes neuronales recurrentes a la predicción de emisiones contaminantes de autobuses urbanos. [Tesis de Maestría, Universidad Politécnica de Madrid]. Archivo digital. <http://www.oa.upm.es>

Mestizo, S., Cruz, N., Morales, E., Leines, C. (2020). Un caso de estudio para la predicción de las partículas contaminantes PM_{2.5} mediante redes bayesianas. *Temas de Ciencia y Tecnología*, 24(72): 51 - 55. <http://www.utm.mx>

Mora-Flórez, J., Granada Echeverri, M., Marín Castañeda, L. E. (2005). Los métodos de representación del conocimiento en inteligencia artificial y su integración en sistemas híbridos de localización de fallas. *Tecnura*. (9):17, 98-109. <http://www.redalyc.org/articulo.oa?id=257021014009>

Nagendra S.M. and Mukesh K. (2005). Modelling urban air quality using artificial neural network. *Clean Technologies and Environmental Policy*. 7(2):116 – 126. http://www.researchgate.net/publication/226568851_Modelling_urban_air_quality_using_artificial_neural_network

OECD (2019), Artificial Intelligence in Society, www.oecd.org/going-digital/artificialintelligencein-society-ceedfee77-en.htm; OECD (2019), Recommendation of the Council on Artificial Intelligence, <https://legalinstruments.oecd.org/en/instruments/OECD-LEGAL-0449>

Ordieres, J., González, A., Alba, F., Martínez, F.J. (s.f.). MD para la predicción de los niveles de ozono troposférico. II Congreso Español de Informática. <http://www.Isi.us.es>

Paredes, D. J. (2021). Predicción temporal de calidad del aire en Lima a partir de datos de estaciones de bajo costo y Aprendizaje Automático: una revisión de literatura. [Tesis de Grado, Pontificia Universidad Católica del Perú]. Archivo digital. <http://repositorio.pucp.edu.pe>

Pedraza, J. C. (2019). Prototipo de un modelo de machine learning para la predicción de partículas de contaminación atmosférica finas, en la localidad de Kennedy en Bogotá. [Tesis de Grado, Universidad Distrital Francisco José de Caldas]. Archivo digital. <http://repository.udistrital.edu.co>

Qian, M. (2005). Neural network learning for time-series predictions using constrained formulations. University of Illinois at Urbana-Champaign (como se citó en Sepúlveda, P.I., 2011). Redes neuronales recurrentes con algoritmo de optimización por enjambre de partículas para pronóstico multivariado de captura de anchovetas en el norte de Chile. [Tesis de Grado, Pontificia Universidad Católica de Valparaíso]. Archivo digital. <http://www.ideals.illinois.edu>

Ravina Ripoll R, Bocoya Maline J, Gutiérrez Montoya G.A, Mejía Castillo F.N. (2018). Los Árboles de Decisión. Una Herramienta práctica para la Toma de Decisiones del Happy Manager. Fondo Editorial UNERMB. http://150.185.9.18/fondo_editorial/

Rodríguez Miranda, A. (2018). Modelización y análisis de la calidad del aire en la ciudad de Oviedo (norte de España), mediante los enfoques PSO-SVM, red neuronal MLP y árbol de regresión M5. [Tesis Doctoral, Universidad de León]. Archivo digital. <http://buleria.unileon.es/hdl.handle.net/10612/7963>

Rojas E. I. (2018). Comparación de un modelo híbrido obtenido de la mezcla de vectores autorregresivos y la metodología de redes neuronales artificiales ann-var y un modelo econométrico de vectores autorregresivos (var) para la predicción del nivel de PM_{2,5} en Santiago de Chile. [Tesis de Grado, Universidad Técnica Federico Santa María, Valparaíso]. Archivo digital. <http://www.repositorio.usm.cl>

Ruiz, C. (2017). Técnicas de aprendizaje automático para el análisis de datos de calidad del aire. [Tesis de Grado, Universidad Autónoma de Madrid]. Archivo digital. <http://www.repositorio.uam.es>

Salini Calderon G. and Pérez Jara P. (2006). Estudio de series temporales de contaminación ambiental mediante técnicas de redes neuronales artificiales. Revista Chilena de Ingeniería, 14(3): 284-290. <http://www.scielo.cl/dx.doi.org/10.4067/S0718-33052006000200012>

Sánchez, E., Ortiz, M. L., Castrejón, M. L. (2014). Contaminación urbana del aire: aspectos fisicoquímicos, microbiológicos y sociales. Universidad autónoma del estado de Morelos. <http://www.uaem.mx>

Sánchez, N. (2020). Estudio comparativo de modelos de predicción estocásticos y heurísticos aplicados a la estimación de la calidad del aire. [Tesis de Maestría, Universidad Oberta de Catalunya]. Archivo digital. <http://www.openaccess.uoc.edu/hdl.handle.net/10609/123386>

Sanjuán, M. (2020). Predicción de la calidad del aire de la ciudad de Madrid mediante técnicas de machine – learning. [Tesis de Maestría, Universidad Oberta de Catalunya]. Archivo digital. <http://www.openaccess.uoc.edu>

Serrano, J., Soria, E., Martín, J.D. (2010). Redes neuronales artificiales. [Programa 3er ciclo de doctorado, curso 2009-2010]. Universidad de Valencia. <http://www.ocw.uv.es>

Scutari, M. y Denis, J.B. (2014). Bayesian networks: with examples in R. Chapman and Hall/CRC, (como se citó en Bermejo, G., 2019). Aplicación de redes bayesianas en el análisis de supervivencia. [Tesis de Maestría, Centro de Investigación en Matemáticas, Guanajuato]. Archivo digital. <http://www.researchgate.net>

Winograd, T. A., Flores, F. (1986). Understanding Computers and Cognition. Norwood, N.J (como se citó en Aguilar M.A., 2016). Sistema de razonamiento basado en casos, para la mejora de atención de salud en un centro rural. [Tesis de Maestría, Universidad Nacional Mayor de San Marcos]. Archivo digital. <http://www.amazon.com>