



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERÍA

**Desempeño de un modelo de estimación
del contaminante atmosférico PM2.5 en la
Ciudad de México, mediante análisis
multitemporal**

TESIS

Que para obtener el título de

Ingeniero Civil

P R E S E N T A N

Alondra Orozco Gómez

Miguel Ángel Sánchez Caro

DIRECTOR DE TESIS

M.I. Rodrigo Takashi Sepúlveda Hirose



Ciudad Universitaria, Cd. Mx., 2023

AGRADECIMIENTOS

MIGUEL ÁNGEL SÁNCHEZ CARO

A mis padres, por el inconmensurable esfuerzo que hicieron por proveerme con la educación y las herramientas que me llevaron al lugar en el que me encuentro. Por su apoyo incondicional en todos los aspectos de mi vida, este logro es gracias a ustedes.

A mi hermano; tías, tíos; primas y primos. Una familia que siempre mostró orgullo por mí.

A mis abuelos, porque fueron mis maestros de vida y siempre creyeron en mí. Los llevo conmigo cada día.

A toda la gente valiosa que conocí, dentro y fuera de la universidad, y con los que compartí este enredoso camino. Ustedes hicieron de esta, una de las mejores etapas de mi vida.

A mi compañera de tesis. Es un honor compartir este trabajo contigo.

AGRADECIMIENTOS ALONDRA OROZCO GÓMEZ

A mi mamá y mi papá, por todo el esfuerzo que han hecho para darme la mejor educación y por apoyarme incondicionalmente para que consiguiera mis metas, sin ustedes no habría llegado hasta donde estoy ahora, les dedico este logro.

A Daniela, por estar siempre para mí, fue muy especial estar en la FI al mismo tiempo que tú.

A Alejandra, por inspirarme a ser mejor todos los días.

A Carla, por los días en la casita y por ser mi compañera de viajes favorita.

A Miguel, por compartir este trabajo conmigo, por fin lo logramos.

AGRADECIMIENTOS ESPECIALES

Extendemos un agradecimiento a la Secretaría de Educación, Ciencia, Tecnología e Innovación de la Ciudad de México por el consejo y apoyo que nos otorgaron durante nuestra estancia en el proyecto SECITI/089/2017 "Desarrollo de modelos para la estimación de material particulado suspendido de la Zona Metropolitana de la Ciudad de México mediante el uso de imágenes satelitales e información geoespacial", sin ustedes esta tesis no hubiera sido posible.

De igual forma agradecemos a ExxonMobil por otorgarnos la 'Beca ExxonMobil para la Investigación', gracias por creer en este trabajo y en nosotros, todos sus consejos y apoyo fueron fundamentales para nuestro desarrollo personal y profesional durante esta etapa; y al Institute of International Education por acompañarnos en cada paso de este camino.

Agradecemos a la UNAM por todas las oportunidades que nos brindó durante esta etapa, por sus profesores y por su aportación a la educación del país.

A ICEIIS, en especial al Maestro Rodrigo y la Doctora Ana, por acercarnos a la investigación y crear un espacio donde se hacen grandes amigos y colaboradores.

ÍNDICE

Agradecimientos	i
Agradecimientos especiales.....	iii
Resumen	vii
Abstract	viii
Introducción.....	1
1. Antecedentes del material particulado y la percepción remota	3
1.1. Material particulado	3
1.2. Percepción remota	4
1.2.1 Radiación electromagnética	5
1.2.2 Elementos de un sistema de percepción remota.....	9
1.2.3 Resolución de un sensor.....	10
1.2.4 Satélite Landsat 8.....	12
1.3. Redes neuronales	15
1.4. Zona de estudio.....	17
1.4.1 Ubicación geográfica	17
1.4.2 Clima	21
1.5. Monitoreo atmosférico en la Ciudad de México	23
1.5.1 Evolución del monitoreo de contaminantes en México	23
1.5.2 Normatividad	25
1.5.3 Estaciones de monitoreo atmosférico.....	29
1.5.4 Estaciones meteorológicas	32

1.5.5	Aire y salud.....	32
1.6.	Objetivos	34
1.6.1	Objetivo general.....	34
1.6.2	Objetivos particulares.....	34
1.7.	Hipótesis.....	35
2.	Estado del arte en la investigación para la estimación de contaminantes atmosféricos	36
3.	Metodología para ejecutar el modelo predictivo.....	39
3.1.	Fuentes de información.....	39
3.1.1	Imágenes satelitales	39
3.1.2	Datos meteorológicos	39
3.1.3	Registro de estaciones de monitoreo ambiental	40
3.1.4	Modelos de estimación de PM _{2.5}	40
3.2.	Procedimientos	41
3.2.1	Selección del modelo a evaluar	41
3.2.2	Selección de fechas a comparar	41
3.2.3	Procesamiento de la información de reflectancias	42
3.2.4	Obtención de datos meteorológicos del PEMBU.....	43
3.2.5	Unificación de datos	45
3.2.6	Aplicación del modelo y elaboración de mapas de concentraciones de PM _{2.5}	45
4.	Resultados y discusión	47
4.1.	Desempeño predictivo del modelo	47

4.1.1	Datos del modelo predictivo y medidos en campo	47
	Temporada de estiaje 2016	48
	Temporada de lluvia 2016.....	51
	Temporada de estiaje 2018	54
	Temporada de Lluvia 2018	57
	Temporada de estiaje 2019	60
	Temporada de lluvia 2019	63
4.1.2	Criterios de selección.....	66
4.1.3	Mapas de concentraciones de PM _{2.5}	66
4.1.4	Evaluación multitemporal del modelo	66
5.	Conclusiones y continuidad	68
5.1.	Limitaciones del estudio.....	68
5.2.	Recomendaciones	69
	Lista de figuras	71
	Lista de tablas.....	73
	Referencias	74

RESUMEN

La calidad del aire se ha vuelto un tema de preocupación global en las últimas décadas. El deterioro de la calidad del aire, producto de la presencia de contaminantes atmosféricos, tiene consecuencias negativas en el medio ambiente y por lo tanto en la salud humana. Este es el caso del material particulado PM (Particulate Matter), emitido como resultado de las actividades diarias del ser humano y de la industria, que generan una importante cantidad de sustancias que modifican la composición natural del aire. El monitoreo continuo de contaminantes atmosféricos es esencial para el diseño y ejecución de medidas de mitigación, así como para informar y educar a la población sobre los riesgos de exposición. Sin embargo, el trabajo de campo requerido para monitorear la calidad del aire es ineficiente debido a su alto costo económico y humano.

Para el desarrollo de este proyecto, se parte de modelos generados con el uso de redes neuronales artificiales que procesan imágenes satelitales obtenidas del sensor Operational Land Imager (OLI) del satélite Landsat 8 e información recopilada de registros meteorológicos históricos de las estaciones de la Red Automática de Monitoreo Atmosférico (RAMA) de la Dirección de Monitoreo Atmosférico de la Ciudad de México. Se llevó a cabo un análisis para determinar el mejor comportamiento de los modelos comparando su precisión al procesar información con variabilidades en el espacio y tiempo de la zona de estudio, así como la determinación de distintas variables meteorológicas para evaluar el desempeño más preciso de los modelos.

El fin de este trabajo es proporcionar un análisis comparativo del desempeño multitemporal de modelos predictivos de $PM_{2.5}$ que puedan complementar al actual sistema de monitoreo al reducir costos y lograr una cobertura completa de la zona de estudio. Adicionalmente, esta metodología puede ser aprovechada para la toma de decisiones enfocadas en la protección de la salud de los pobladores de la Ciudad de México, en especial la de los grupos vulnerables.

ABSTRACT

Air quality has become a topic of major concern on a global scale throughout the last decades. The deterioration of air quality, due to the presence of atmospheric pollutants, has negative consequences on the environment and therefore on human health. This is the case of PM (Particulate Matter), emitted because of the daily activities of humans and industry, which generate a significant number of substances that modify the natural composition of the air. Continuous monitoring of air pollutants is essential for the design and implementation of mitigation measures, as well as to inform and educate the population about the risks of exposure. However, the field work required to monitor air quality is inefficient due to its high economic and human cost.

For the development of this project, we start from models generated with the use of artificial neural networks that process satellite images obtained from the Operational Land Imager (OLI) sensor of the Landsat 8 satellite and information collected from historical meteorological records of the stations of the Automatic Network of Atmospheric Monitoring (RAMA) of the Atmospheric Monitoring Directorate of Mexico City. An analysis was carried out to determine the best behavior of the models by comparing their accuracy when processing information with variability in space and time in the study area, as well as the determination of different meteorological variables to evaluate the most accurate performance of the models.

The purpose of this work is to provide a comparative analysis of the multitemporal performance of PM_{2.5} predictive models that can complement the current monitoring system by reducing costs and achieving a complete coverage of the study area. Additionally, this methodology can be used for decision making focused on the protection of the health of the inhabitants of Mexico City, especially vulnerable groups.

INTRODUCCIÓN

Actualmente, se estima que un 99% de la población mundial está expuesta a aire con una calidad que excede los límites establecidos por la Organización Mundial de la Salud en sus lineamientos globales de calidad de aire del 2021, donde se presenta la evidencia que demuestra que la contaminación atmosférica causada por el material particulado suspendido es un factor de riesgo en el padecimiento de cardiopatías, accidentes cerebrovasculares, enfermedades pulmonares, asma, cáncer, entre otras afecciones a la salud.

Se estima que cada año, la exposición a contaminantes atmosféricos causa millones de muertes y la pérdida de años sanos de vida. La naturaleza de esta problemática ha llevado a los gobiernos del mundo a implementar políticas, basadas en evidencia científica, para monitorear de cerca y mejorar la calidad del aire.

Según la Organización Mundial de la Salud, más de 6000 ciudades en 117 países están monitoreando rutinariamente la calidad del aire, a pesar de esto, aún existen brechas que impiden una cobertura óptima del monitoreo de distintos contaminantes atmosféricos, que están relacionados con la variabilidad espacial de estos dentro de las ciudades. En los últimos años ha habido una mejora significativa de esta problemática, gracias a la combinación de recuperación de datos satelitales y el uso de mediciones tomadas en campo.

En este trabajo se realiza un análisis comparativo del desempeño multitemporal de modelos predictivos de $PM_{2.5}$, generados a través de la combinación de técnicas de percepción remota y la implementación de redes neuronales artificiales, procesando imágenes satelitales del sensor OLI de Landsat 8 y datos históricos de registros de concentración de $PM_{2.5}$ de la RAMA de la Dirección de Monitoreo Atmosférico de la Ciudad de México, así como datos meteorológicos de la red PEMBU.

El primer capítulo de este trabajo tiene como objetivo definir qué es el material particulado y la necesidad del monitoreo de este contaminante atmosférico. Se presenta el contexto de

los elementos de la percepción remota, como las características técnicas de los satélites y las mediciones que realizan. Adicionalmente, se describen las bases del método utilizado para la obtención del modelo de estimación en el que se basa el trabajo. Finalmente, se hace referencia a las características de la zona de estudio que son relevantes para el desarrollo de la investigación.

En el segundo capítulo, “Estado del arte en la investigación para la estimación de contaminantes atmosféricos”, se hace referencia a otras investigaciones publicadas que relacionan la medición y estimación de material particulado, técnicas de percepción remota y aplicación de modelos desarrollados con redes neuronales artificiales. ha hecho después de elaborar modelos de estimación de contaminantes atmosféricos con percepción remota en diferentes ubicaciones geográficas.

En el tercer capítulo se presenta el procedimiento que se siguió para la elaboración de este trabajo, comenzando por recopilar información de bases de datos proporcionadas por diferentes organismos. Posteriormente, la información fue procesada utilizando diversos métodos y herramientas para obtener los datos requeridos con el fin de determinar la veracidad o falsedad de la hipótesis planteada previamente.

En el cuarto capítulo se presentan los resultados de las seis fechas seleccionadas. Para cada una de las estaciones de monitoreo se muestran los valores medidos en campo contra los predichos por el modelo de estimación de $PM_{2.5}$, así como el error absoluto. Para cada fecha se obtuvo el error medio absoluto y se elaboró un mapa de concentraciones con los valores estimados.

El último capítulo, "Conclusiones y Continuidad", se presentan las conclusiones clave que se derivan de la investigación, relacionando los objetivos y la veracidad de la hipótesis planteada al comienzo del estudio. Se discuten las limitaciones halladas en el desarrollo del trabajo, se plantean las recomendaciones para guiar futuras investigaciones y realizar aplicaciones prácticas en el monitoreo de contaminantes atmosféricos para el beneficio de la sociedad.

1. ANTECEDENTES DEL MATERIAL PARTICULADO Y LA PERCEPCIÓN REMOTA

1.1. MATERIAL PARTICULADO

El material particulado (PM) es un tipo de contaminante atmosférico, que consiste en una mezcla heterogénea de partículas sólidas y líquidas suspendidas en el aire que varían continuamente en tamaño y composición química en el espacio y el tiempo (Health Organization & Office for Europe, 2013).

La Agencia de Protección Ambiental de los Estados Unidos (EPA: United States Environmental Protection Agency) divide las partículas en dos categorías de tamaño principales, en función de su capacidad de penetración esperada en el pulmón (Esworthy, 2015), como partículas gruesas (PM₁₀) con un diámetro aerodinámico de 10 µm o menor y partículas finas (PM_{2.5}) con un diámetro aerodinámico menor a 2,5 µm (United States Environmental Protection Agency, 2016). En la figura 1 se observa una comparación entre el tamaño de las partículas de PM contra un cabello humano y arena fina de playa.

La composición y origen del material particulado es muy variado, puede provenir tanto de fuentes naturales como antropogénicas (Health Organization & Office for Europe, 2013). Las partículas finas (PM_{2.5}) suelen relacionarse con la combustión de carbón, petróleo, gasolina; productos de transformación de NO_x, SO₂, incluidos los orgánicos biogénicos, por ejemplo, los terpenos; procesos de alta temperatura; fundiciones y la industria siderúrgica. Las partículas gruesas (PM₁₀) se asocian al polvo arrastrado de carreteras y calles, suelos agrícolas y mineros, construcción, combustión de carbón y petróleo, y aerosoles oceánicos (Kim et al., 2015).




Figura 1.1 Comparación de tamaño de partículas de PM_{2.5} (United States Environmental Protection Agency, 2016)

Se ha comprobado que la exposición a altas concentraciones de material particulado tiene numerosos efectos sobre la salud, provocando el aumento de los ingresos hospitalarios, visitas a urgencias, síntomas respiratorios, exacerbación de enfermedades respiratorias y cardiovasculares crónicas, disminución de la función pulmonar y la mortalidad prematura (Kim et al., 2015). Los adultos mayores, niños y personas con enfermedades pulmonares o del corazón están sujetos a un riesgo mucho mayor al estar expuestos a estas partículas (Kim et al., 2015).

1.2. PERCEPCIÓN REMOTA

La percepción remota es la ciencia de obtener información sobre un objeto, área o fenómeno mediante el análisis de datos adquiridos por un dispositivo que no está en contacto directo con el objeto, área o fenómeno investigado (Congalton, 2015).

La percepción remota proporciona información sobre los objetos que se encuentran en la superficie de la Tierra y en la atmósfera, basándose en la radiación reflejada o emitida por esos objetos. La información suele captarse a distancia en forma de datos de imagen. Estos datos permiten determinar la composición y la naturaleza de la superficie y la atmósfera de

la Tierra, desde la escala local hasta la global, y evaluar los cambios mediante el análisis de las imágenes captadas en distintos momentos (Read & Torrado, 2009).

1.2.1 RADIACIÓN ELECTROMAGNÉTICA

La interpretación de imágenes de percepción remota depende del entendimiento de la radiación electromagnética y su interacción con las superficies y la atmósfera. Todos los objetos con una temperatura mayor que el cero absoluto reflejan y emiten radiación. En percepción remota, la radiación se mide y se clasifica en función de la longitud de onda usando la escala logarítmica (Campbell & Wynne, 2011), de acuerdo con el espectro electromagnético, que se refiere al rango de todos los tipos de radiación electromagnética (National Aeronautics and Space Administration Goddard Space Flight Center, 2013).

El espectro electromagnético tiene siete divisiones principales (tabla 1.1), estas han sido definidas arbitrariamente y pueden variar dependiendo de la fuente de consulta. En percepción remota las divisiones más empleadas son el espectro ultravioleta, el espectro visible, el espectro infrarrojo y la energía de microondas. Esta clasificación se representa gráficamente en la figura 1.2.

- a) **Espectro ultravioleta.** Zona de radiación de longitud de onda corta que se encuentra entre la región de los rayos X y el límite de la visión humana. A menudo, la región ultravioleta se subdivide en ultravioleta cercano (a veces conocido como UV-A; 0,32-0,40 μm), ultravioleta lejano (UV-B; 0,32-0,28 μm) y ultravioleta extremo (UV-C; por debajo de 0,28 μm). La radiación ultravioleta se dispersa fácilmente por la atmósfera terrestre, por lo que no suele utilizarse para la percepción remota de materiales terrestres (Campbell & Wynne, 2011). Es emitida por el Sol y cuerpos “calientes” en el espacio (National Aeronautics and Space Administration Goddard Space Flight Center, 2013).
- b) **Espectro visible.** Aunque el espectro visible representa una fracción muy pequeña del espectro electromagnético, tiene una importancia evidente en la percepción remota. Los límites del espectro visible están definidos por la sensibilidad del

sistema visual humano (Campbell & Wynne, 2011). Cuando el espectro completo de la luz visible atraviesa un prisma, las longitudes de onda se separan en los colores del arco iris porque cada color tiene una longitud de onda diferente. El violeta tiene la longitud de onda más corta, de unos 380 nm, y el rojo la más larga, de unos 700 nm (Butcher & Mottar, 2016).

- c) **Espectro infrarrojo.** Las longitudes de onda más largas que la parte roja del espectro visible se denominan región infrarroja. Este segmento del espectro es muy amplio en relación con la región visible, ya que se extiende desde 0,72 hasta 15 μm , lo que lo hace más de 40 veces más ancho que el espectro de luz visible. Mientras que la radiación infrarroja cercana es esencialmente radiación solar reflejada por la superficie de la Tierra, la radiación infrarroja lejana es emitida por la Tierra. En el lenguaje común, el infrarrojo lejano consiste en "calor" o "energía térmica" (Campbell & Wynne, 2011). La radiación infrarroja cercana reflejada puede ser detectada por los satélites, lo que permite a los científicos estudiar la vegetación desde el espacio, también puede ayudar a identificar tipos de roca y suelo (Butcher & Mottar, 2016).
- d) **Radiación de microondas.** Las longitudes de onda más largas que se utilizan habitualmente en percepción remota son las que van de 1 mm a 1 μm de longitud de onda aproximadamente (Campbell & Wynne, 2011). Las diferentes longitudes de onda de las microondas (agrupadas en "sub-bandas") proporcionan diferente información a los científicos. Las microondas de longitud media (banda C) penetran a través de las nubes, el polvo, el humo, la nieve y la lluvia para revelar la superficie de la Tierra. Las microondas de banda L, como las que utiliza un receptor del Sistema de Posicionamiento Global (GPS), pueden penetrar la cubierta de los bosques para medir la humedad del suelo en las selvas. La mayoría de los satélites de comunicaciones utilizan las bandas C, X y Ku para enviar señales a una estación terrestre (Butcher & Mottar, 2016).

Tabla 1.1 Principales divisiones del espectro electromagnético (Campbell & Wynne, 2011)

División	Longitud de onda
Rayos Gamma	< 0.03 nm
Rayos X	0.03-300 nm
Radiación ultravioleta	0.30-0.38 μm
Luz visible	0.38-0.72 μm
Radiación infrarroja	
Infrarrojo cercano	0.72-1.30 μm
Infrarrojo medio	1.30-3.00 μm
Infrarrojo lejano	7.0-1,000 μm (1 mm)
Radiación de microondas	1 mm-30 cm
Banda L	15 cm-30 cm
Banda C	3.75 cm-7.50 cm
Banda X	25 cm-37.50 cm
Banda Ku	16.70 mm-25 mm
Ondas de radio	\geq 30 cm

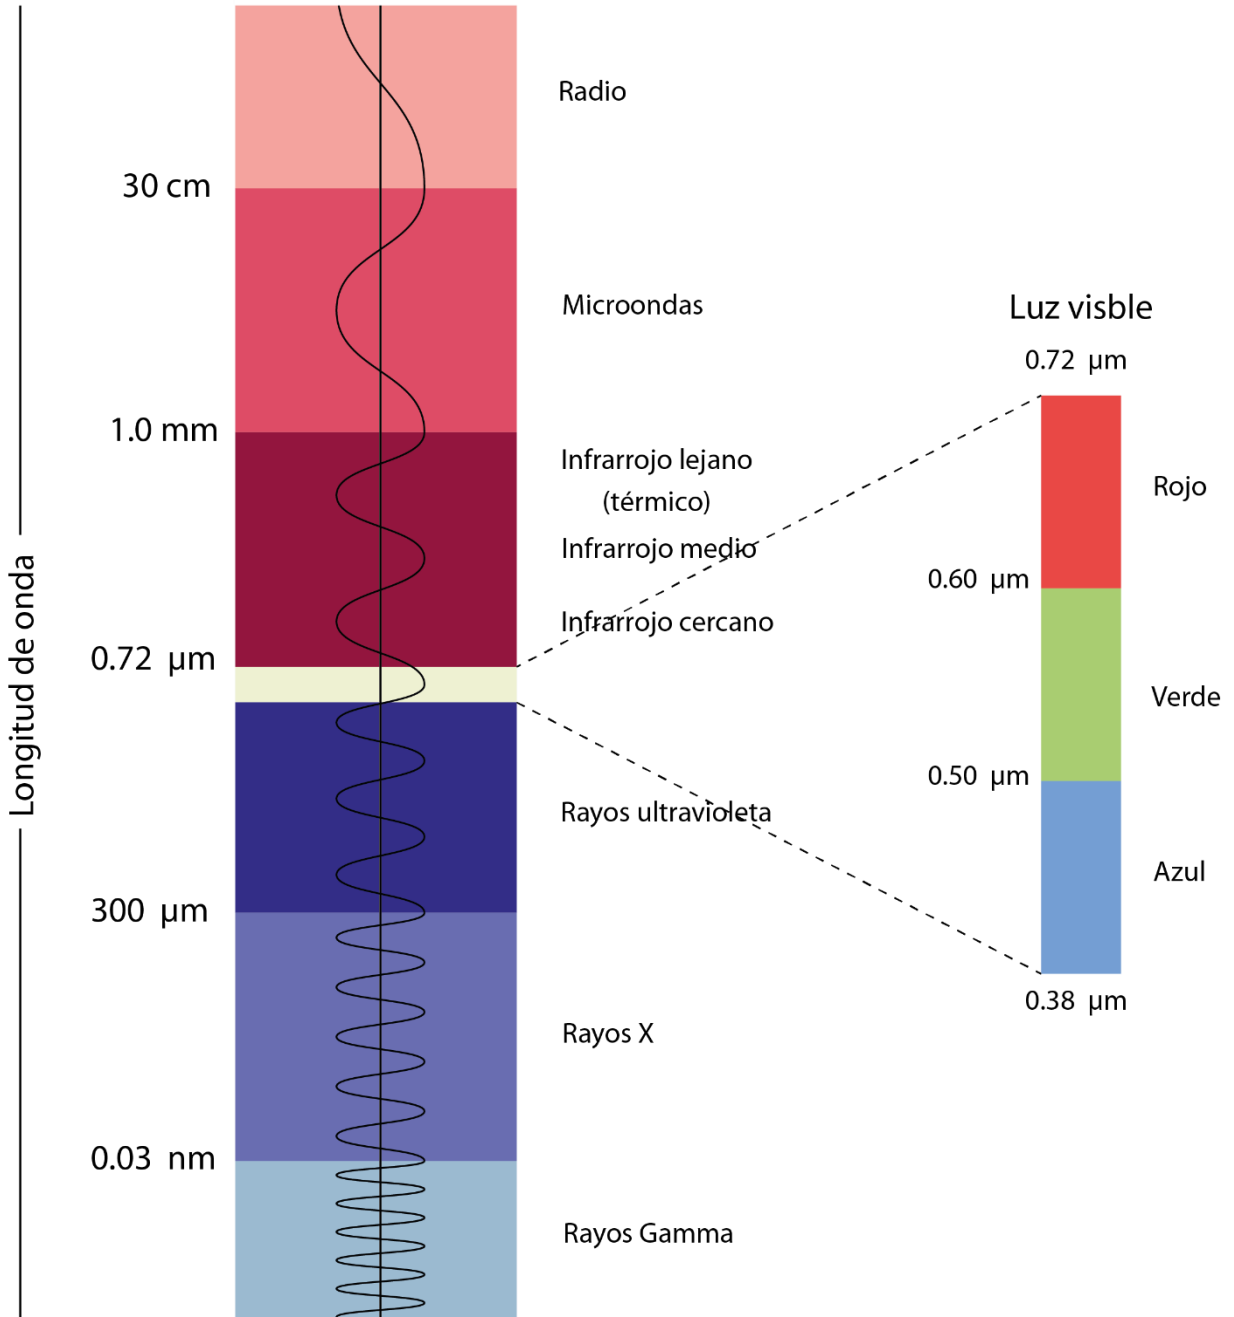


Figura 1.2 Espectro electromagnético

1.2.2 ELEMENTOS DE UN SISTEMA DE PERCEPCIÓN REMOTA

En un sistema de percepción remota están involucrados dos procesos básicos, que son la adquisición de datos y el análisis de estos. Los elementos involucrados en estos procesos se describen a continuación (Congalton, 2015), estos se observan en la figura 1.3.

- a) **Fuente de energía.** Se requiere energía originada en fuentes distintas al propio sensor, normalmente en forma de radiación reflejada por el sol o de radiación emitida por elementos localizados en la superficie terrestre.
- b) **Atmósfera.** La atmósfera es el medio de transmisión de la energía electromagnética que viaja desde la fuente al objeto y que después es reflejada y captada por el sensor. Durante este proceso cuando la energía entra en contacto con la atmósfera una parte es absorbida, otra se dispersa y otra atraviesa la atmósfera.
- c) **Interacción con el objeto.** Cada material refleja y/o emite energía en una forma especial, a esto se le llama respuesta espectral. Aunque los patrones de respuesta espectral desempeñan un papel fundamental en la detección, identificación y análisis de los materiales de la superficie terrestre, el mundo espectral está lleno de ambigüedades. Materiales radicalmente diferentes pueden tener una gran similitud espectral, lo que dificulta su identificación.
- d) **Sensor.** Este es el responsable de captar la radiación electromagnética reflejada, dispersada o emitida por el objeto y la atmósfera, para almacenar los datos en forma digital.
- e) **Transmisión, recepción y procesamiento de datos.** Los datos captados por el sensor se transmiten a una estación de recepción, actualmente se emplean entornos computacionales en la nube, donde son procesados y convertidos en imágenes digitales.
- f) **Interpretación y análisis.** Las imágenes procesadas son interpretadas, tanto visual como digitalmente, con el propósito de extraer información de interés.

g) Usuario y aplicación. Los datos colectados toman sentido cuando existen usuarios que los utilizan como información para la realización de distintos proyectos o estudios que permitan resolver problemas.

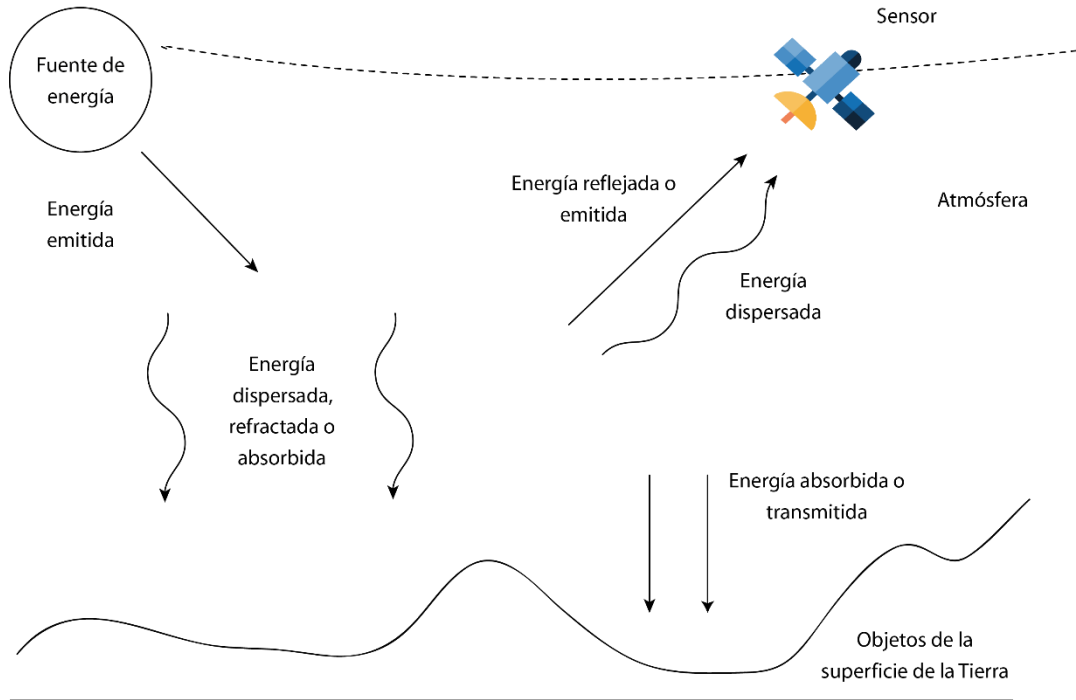


Figura 1.3 Elementos de un sistema de percepción remota

1.2.3 RESOLUCIÓN DE UN SENSOR

La resolución está determinada por las características del sistema de percepción remota en su conjunto, incluidas las características del sensor o sensores y los parámetros orbitales (Read & Torrado, 2009). Hay cuatro tipos de resolución (espacial, espectral, radiométrica y temporal) que determinan el detalle capturado y mostrado.

a) Resolución espacial. Todos los sistemas de percepción remota tienen un límite en cuanto al objeto en la superficie terrestre más pequeño que pueda distinguir un sensor como algo separado de su entorno (Congalton, 2015). Se define por el tamaño de cada píxel dentro de una imagen digital y el área de la superficie de la Tierra representada por ese píxel. Cuanto más fina sea la resolución (cuanto más bajo sea

el número), más detalles se podrán observar (National Aeronautics and Space Administration, 2021). Se mide en unidades de longitud, usualmente en metros.

- b) **Resolución espectral.** Se refiere a la capacidad de un sensor para distinguir entre las diferentes características del terreno en función de sus propiedades espectrales. La resolución espectral depende del número, la ubicación de la longitud de onda y la estrechez de las bandas espectrales en las que un sensor recoge datos de imágenes. Las bandas en las que un sensor recopila datos pueden variar desde una sola banda (para imágenes pancromáticas), unas cuantas bandas (para imágenes multiespectrales) o muchas bandas muy estrechas (para imágenes hiperespectrales) (Congalton, 2015).
- c) **Resolución radiométrica.** Se define como la capacidad de un sensor para registrar las variaciones de luminosidad (radiancia espectral). La resolución radiométrica gruesa registraría una escena utilizando sólo unos pocos niveles de brillo o unos pocos bits (es decir, con un contraste muy alto), mientras que la resolución radiométrica fina registraría la misma escena utilizando muchos niveles de brillo (Campbell & Wynne, 2011). La resolución espectral denota la capacidad de un sensor para definir intervalos finos de longitud de onda. Cuanto más fina sea la resolución radiométrica, mayor será la calidad y la interpretabilidad de una imagen (National Aeronautics and Space Administration, 2021). La mayoría de los sistemas ofrecen una resolución de 8 bits por píxel, es decir, que tienen 256 niveles por píxel (0-255), sin embargo, algunos sensores llegan a tener una resolución mayor, de 10 bits, 12 bits o hasta 16 bits por píxel (Wright et al., 2015).
- d) **Resolución temporal.** Es el tiempo que tarda un satélite en completar una órbita y volver a pasar por la misma zona de observación. Esta resolución depende de la órbita, de las características del sensor y de la anchura del barrido. Dado que los satélites geoestacionarios coinciden con la velocidad de rotación de la Tierra, la resolución temporal es mucho más fina, de unos 30s a 1min. Los satélites de órbita

polar tienen una resolución temporal que puede variar entre 1 día y 16 días (National Aeronautics and Space Administration, 2021).

1.2.4 SATÉLITE LANDSAT 8

Con casi 50 años de historia, la misión satelital Landsat ha proporcionado el registro temporal más largo de observaciones de la superficie desde el espacio, ofreciendo datos ininterrumpidos que han ayudado a los responsables de la gestión del territorio y a los responsables políticos a tomar decisiones informadas sobre nuestros recursos naturales y el medio ambiente (U.S. Geological Survey, 2021).

La misión comenzó en 1972 con el lanzamiento exitoso del satélite Landsat 1, y fue continuada por una serie de satélites Landsat consecutivos (Landsat 2, 3, 4, 5 y 7) que se han superpuesto temporalmente y proporcionado una cobertura casi global de observaciones de longitud de onda térmica y de reflexión con una fidelidad espectral y espacial cada vez mayor (Roy et al., 2014).

Landsat-8 fue lanzado el 11 de febrero de 2013 desde el Centro Espacial Kennedy por medio de un cohete Atlas V. La Administración Nacional de Aeronáutica y del Espacio (NASA) y el Servicio Geológico del Departamento del Interior (USGS) fueron los principales cooperadores en la concepción y operación de la misión. La NASA fue la principal responsable del segmento espacial de la misión, incluyendo el desarrollo de la nave y los sensores, el lanzamiento de la nave, la ingeniería de sistemas, la calibración previa al lanzamiento y la comprobación en órbita del segmento espacial. El USGS dirigió el desarrollo del sistema terrestre y asumió la operación de la misión tras completar un periodo de comprobación en órbita. Estas operaciones incluyen la calibración posterior al lanzamiento, la programación de la recogida de datos, así como la recepción, el archivo y la distribución de los datos resultantes (Congalton, 2015).

El satélite da la vuelta al globo cada 99 minutos, recogiendo datos sobre las superficies terrestres de cada trayectoria/fila que se sobrepasa; tiene una resolución temporal de 16 días, por lo que cada trayectoria puede adquirirse un máximo de 22 o 23 veces al año

(Goddard Media Studios, 2014). Las escenas están referenciadas con el World-Wide Reference System 2 (WWRS-2) y tienen una dimensión de 185 km por lado.

El Landsat 8 lleva dos sensores, el Operational Land Imager (OLI) y el Thermal Infrared Sensor (TIRS), y almacena más de 500 escenas al día en el archivo de datos del Landsat en el Centro de Ciencia y Observación de Recursos Terrestres (EROS) del USGS, en Dakota del Sur (Roy et al., 2014). Con ambos sensores se recogen once bandas de longitud de onda individuales, en la tabla 2 se especifican las características de cada una, cada banda revela información diferente sobre las condiciones de la cobertura de terreno registrada.




Figura 1.4 Satélite Landsat 8 (NASA, n.d.)

Tabla 1.2 Bandas captadas por el satélite Landsat 8 (U.S. Geological Survey, 2019)

Sensor	No. de banda	Banda	Longitud de onda (μm)	Resolución espacial	Aplicaciones principales	
OLI	1	Costal/Aerosol	0.435-0.451	30 m	Útil para estudios costeros y de aerosoles	
	2	Azul	0.452-0.512		Penetración en cuerpos de agua, útil para el mapeo de aguas costeras. Discriminación de suelos/vegetación, mapeo de tipos de bosques.	
	3	Verde	0.533-0.590		Medición del pico de reflectancia verde de la vegetación para la discriminación de la vegetación y la evaluación de salud vegetal.	
	4	Rojo	0.636-0.673		Identificación de la región de absorción de clorofila, útil en la diferenciación de las especies vegetales.	
	5	Infrarrojo cercano	0.851-0.879		Determinación de tipos de vegetación, salud vegetal y contenido de biomasa. Delimitación de masas de agua. Determinación de la humedad del suelo.	
	6	Infrarrojo de onda corta 1 (SWIR 1)	1.566-1.651		Contenidos de humedad en vegetación y suelo, distinción entre nubes y nieve.	
	7	Infrarrojo de onda corta 2 (SWIR 2)	2.107-2.294		Discriminación de tipo de rocas, alteraciones hidrotermales. También es sensible al contenido de humedad de la vegetación.	
	8	Pancromático	0.503-0.676		15 m	Mejora de la resolución en las imágenes.
	9	Cirrus	1.363-1.384		30 m	Detección de nubes tipo Cirrus.
TIRS	10	Infrarrojo térmico 1 (LWIR 1)	10.6-11.19	100 m	Útil en el análisis del estrés de la vegetación, la determinación de la humedad del suelo y las aplicaciones de cartografía térmica.	
	11	Infrarrojo térmico 2 (LWIR 2)	11.50-12.51			

1.3. REDES NEURONALES

Las redes neuronales, también conocidas como redes neuronales artificiales (RNA), son un subconjunto del aprendizaje automático que pertenece a los algoritmos de aprendizaje profundo. Una red neuronal artificial es una construcción matemática inspirada en el funcionamiento de las redes neuronales biológicas. Las redes neuronales se basan en datos de entrenamiento para aprender y mejorar su precisión con el tiempo. Sin embargo, una vez que estos algoritmos de aprendizaje se afinan en cuanto a precisión, son poderosos modelos, que permiten realizar tareas específicas, son especialmente útiles en el reconocimiento de patrones (IBM, 2020).

Una de las ventajas principales de su implementación es que tienen una inclinación a adquirir conocimiento a través de la experiencia, el cual es almacenado, al igual que en el cerebro, en el peso relativo de las conexiones interneuronales. Tienen altísima plasticidad y gran adaptabilidad, son capaces de cambiar dinámicamente con el medio (Haykin, 1999).

Las redes neuronales se utilizan a menudo para el análisis estadístico y el modelado de datos, su implementación es una alternativa a las técnicas estándar de regresión no lineal o de análisis de conglomerados (Cheng & Titterington, 1994). Por lo tanto, se suelen utilizar en problemas que pueden plantearse en términos de clasificación o predicción. Algunos ejemplos de su aplicación son el reconocimiento de imágenes y de voz, el reconocimiento de texto, entre otras tareas como el diagnóstico médico, el estudio geológico del petróleo y la predicción de indicadores del mercado financiero (McLean, 2000). Una red neuronal artificial es una estructura compuesta por un número de unidades interconectadas (neuronas artificiales) en capas. Cada unidad posee una característica de entrada/salida e implementa una computación local o función. La salida de cualquier unidad está determinada por su característica de entrada/salida, su interconexión con otras unidades y de sus entradas externas (Schalkoff, 1997).

Los elementos de una red neuronal (Amazon Web Services, 2022) se describen a continuación y se pueden observar en la Figura 1.5.

- a) **Capa de entrada.** La información del mundo exterior entra en la red neuronal artificial desde la capa de entrada. Los nodos de entrada procesan los datos, los analizan o categorizan y los pasan a la siguiente capa.
- b) **Capas ocultas.** Las capas ocultas toman su entrada de la capa de entrada o de otras capas ocultas. Las redes neuronales artificiales pueden tener un gran número de capas ocultas. Cada capa oculta analiza la salida de la capa anterior, la procesa y la pasa a la siguiente capa.
- c) **Capa de salida.** La capa de salida proporciona el resultado final de todo el procesamiento de datos realizado por la red neuronal artificial. Puede tener uno o varios nodos.

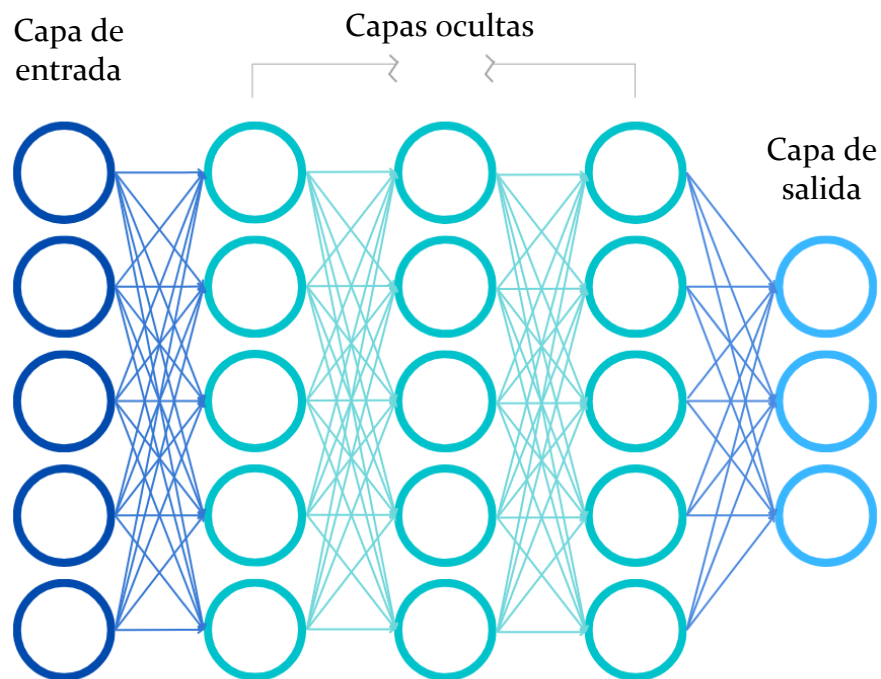


Figura 1.5 Arquitectura de una red neuronal artificial

El entrenamiento ocurre cuando el peso de las conexiones es corregido en función de la coincidencia de la salida prevista para una entrada concreta y la salida registrada en los datos de entrenamiento, es decir, en respuesta a los errores de predicción. El objetivo de cambiar los pesos es modificar la función calculada para que las predicciones sean más correctas en futuras iteraciones (Aggarwal, 2018).

1.4. ZONA DE ESTUDIO

1.4.1 UBICACIÓN GEOGRÁFICA

Este trabajo se limita a la zona que corresponde a la Ciudad de México, figura 1.6. La capital mexicana forma parte de la megalópolis conocida como Zona Metropolitana del Valle de México y se compone de 16 municipios que se extienden en una superficie de 1,494.3 km². Ubicada en un valle a 2,200 metros sobre el nivel del mar, la Ciudad de México se encuentra rodeada al sur, al este y al oeste por cadenas montañosas, Figura 1.7, en las cuales resaltan los volcanes Popocatepetl e Iztaccíhuatl al sudeste del valle (M. J. Molina & Molina, 2004), y delimita con el Estado de México y Morelos.

Otra característica representativa de la Ciudad de México es su elevada cantidad de habitantes. Como parte de la megalópolis de la ZMVM, la Ciudad de México cuenta con 9 209 944 habitantes registrados en el último Censo de Población y Vivienda del INEGI en 2020. En este censo se determinó la densidad poblacional en la CDMX con 6 163.3 habitantes por kilómetro cuadrado, alcanzando densidades de hasta 17,500 habitantes por kilómetro cuadrado en algunas demarcaciones territoriales dentro de la ciudad. De esta forma, la ZMVM supera los 20 millones de habitantes en su población compuesta por la CDMX, 59 municipios del Estado de México y un municipio del estado de Hidalgo (INEGI, 2021).

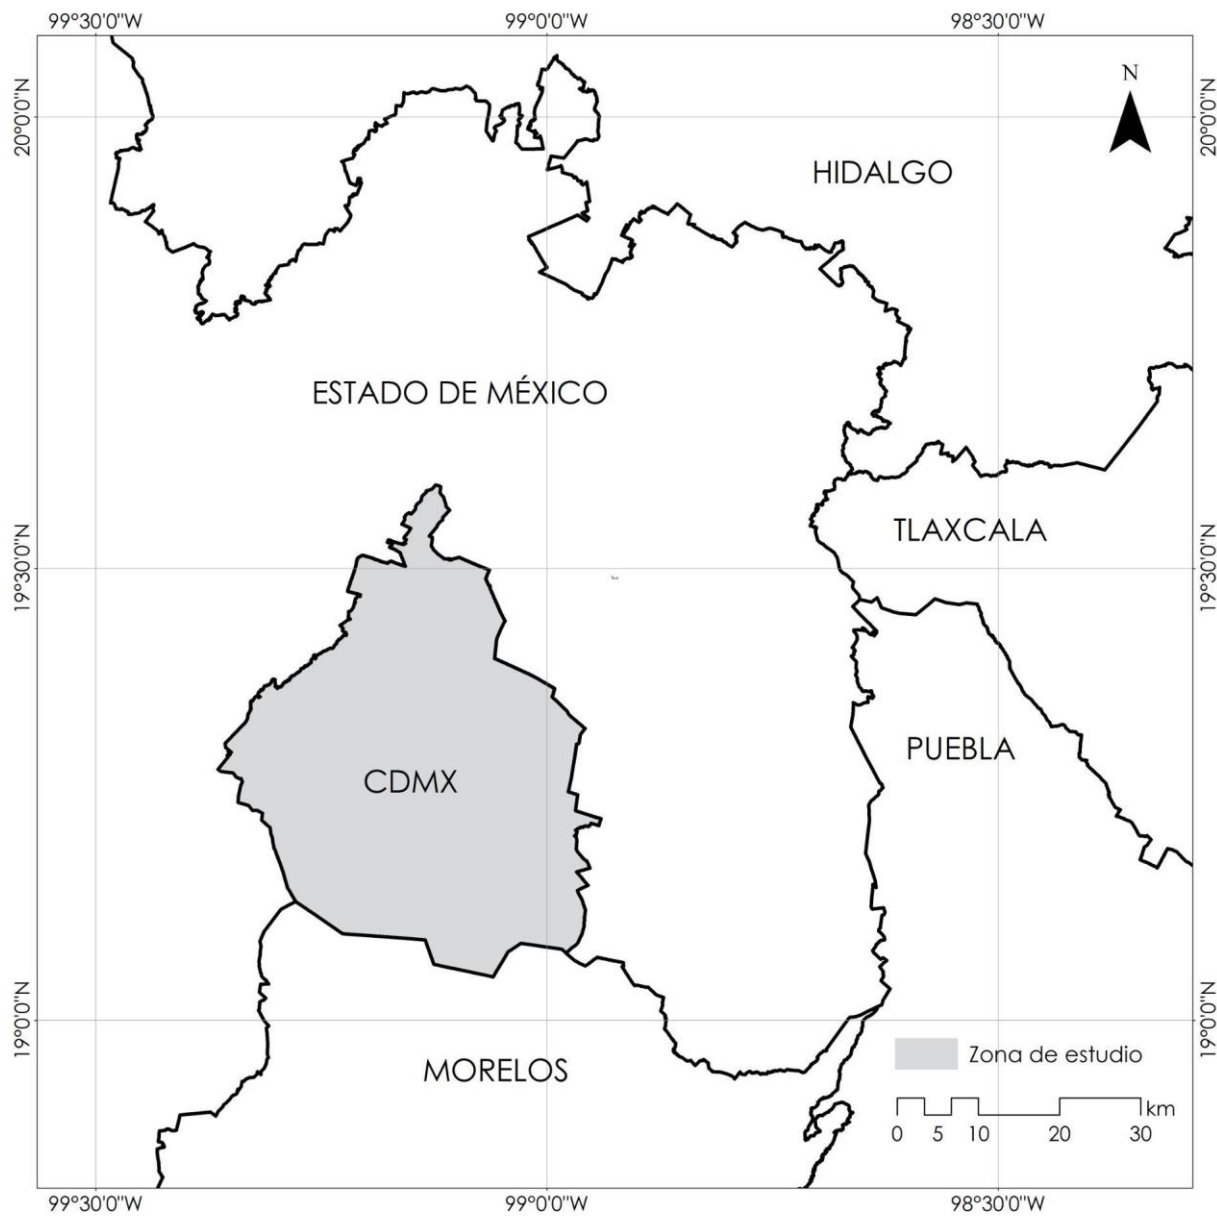


Figura 1.6 Ubicación de la zona de estudio

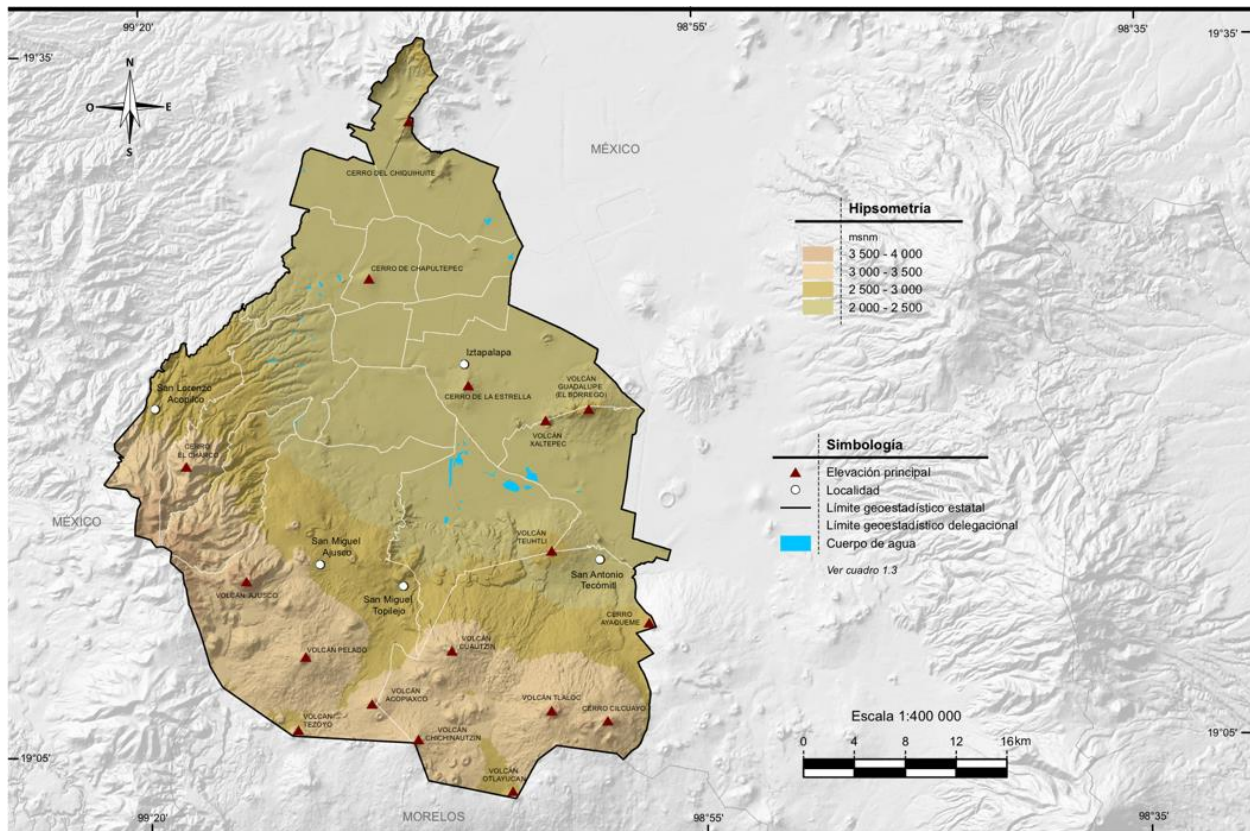


Figura 1.7 Relieve de la Ciudad de México (Instituto Nacional de Estadística y Geografía, n.d.)

Además de las características topográficas de la Ciudad de México, la meteorología es otro factor importante que contribuye a la contaminación atmosférica. Las inversiones térmicas que se dan durante las primeras horas del día ocasionan una acumulación de contaminantes cerca de la superficie (L. T. Molina et al., 2009).

La zona de estudio cuenta con una distribución de suelo particular. Dentro de la ciudad se pueden generalizar tres superficies: vegetación y agricultura, suelo urbano y, por último, cuerpos de agua. Utilizando datos del INEGI, la Procuraduría Ambiental y del Ordenamiento indica que, por un lado, el suelo urbano representa un 41% del total del territorio de la Ciudad de México, principalmente al centro y norte de la capital. Dentro del suelo urbano también se encuentra un porcentaje importante de la superficie de áreas verdes. Por otro lado, el 59% restante de superficie corresponde a suelo de conservación,

que incluye cuerpos de agua al igual que vegetación y suelo utilizado para agricultura (PAOT, 2014). El suelo de conservación se encuentra en mayor porcentaje en el sur de la ciudad en forma de bosque y suelo para agricultura.

La clasificación de las distintas superficies que conforman a la Ciudad de México resulta ser de relevancia para este proyecto puesto que el modelo de estimación de concentración del contaminante $PM_{2.5}$ que se presenta, muestra menor precisión en los datos que genera para las zonas que corresponden al suelo de conservación. Esto se debe a la diferente reflectancia que se da en superficies donde hay presencia de vegetación y cuerpos de agua, comparado con la reflectancia de superficies como concreto y asfalto, que predominan en el suelo urbano.

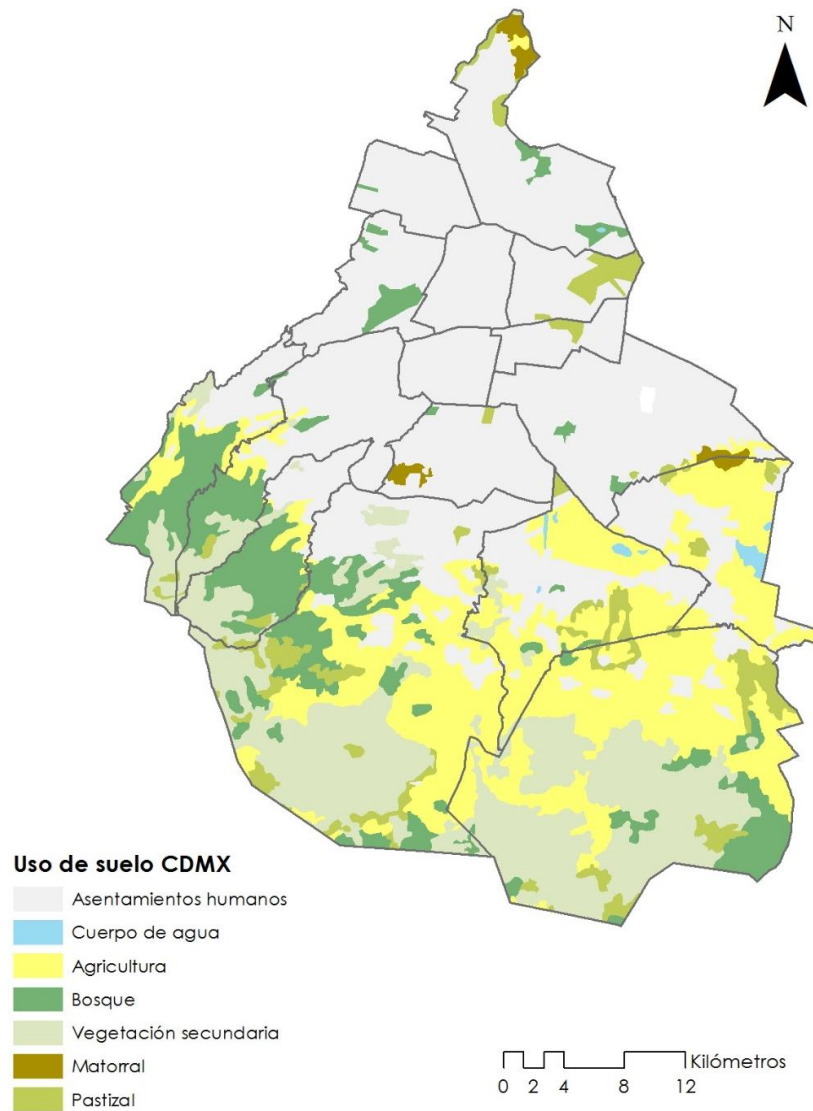


Figura 1.9 Vegetación y agricultura en la Ciudad de México

1.4.2 CLIMA

El clima de la Ciudad de México es tropical, dado a su patrón temporal de precipitaciones, templado por su altitud. Según la clasificación climática universal de Köppen la ciudad presenta tres tipos de clima. Por un lado, se encuentra una zona semiárida templada con clima estepario (BS) en la porción norte-oriental, donde las lluvias son más escasas. La zona centro y sur hallamos un clima templado con invierno seco y lluvias en verano. Como se

observa en la figura 1.9. La estación de lluvias comprende de los meses de mayo a septiembre, mientras que la temporada de estiaje se presenta de octubre a abril, figura 1.10. Las características generales del clima en la CDMX se han mantenido relativamente constantes respecto a su estacionalidad en los últimos siglos, se sigue observando claramente una temporada de lluvias y otra de estiaje, no obstante, la modificación del uso del suelo, la urbanización acelerada, la desecación de lagos y la deforestación, han contribuido a una modificación en la temperatura y los patrones de lluvia en la ciudad, así mismo la calidad del aire se ha deteriorado considerablemente en las últimas décadas (Jáuregui Ostos, 2000).




Figura 1.10 Climas en la Ciudad de México según la clasificación de Köppen

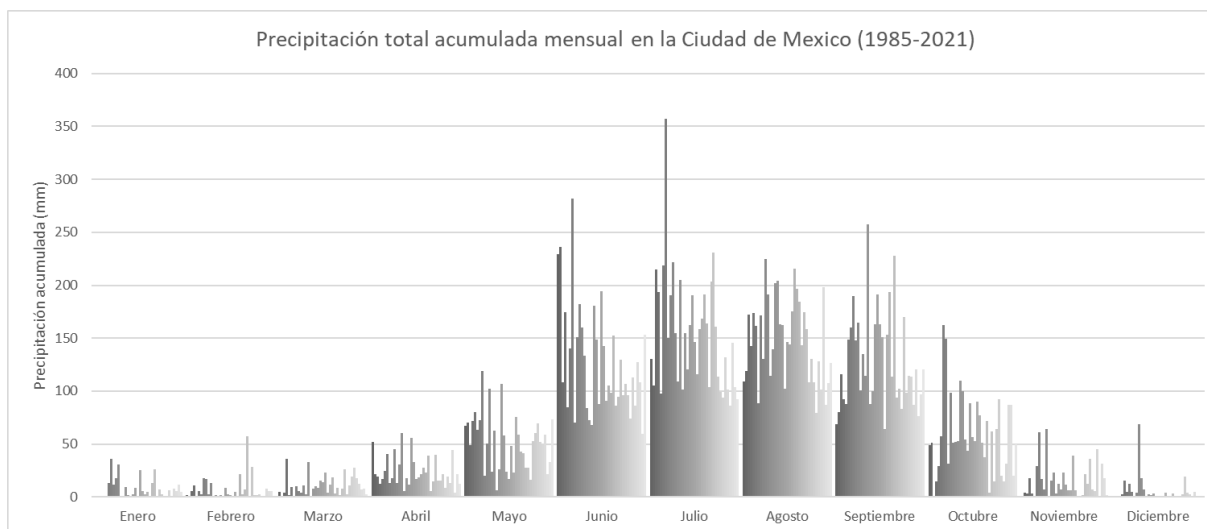


Figura 1.11 Precipitación acumulada mensual en la Ciudad de México de los años 1985 al 2021 (CONAGUA, 2022)

1.5. MONITOREO ATMOSFÉRICO EN LA CIUDAD DE MÉXICO

La medición de los contaminantes del aire es una actividad técnica compleja que involucra el uso de equipo especializado, personal calificado para su operación y una infraestructura adecuada de soporte y comunicaciones. Además de la medición, es necesario asegurar que los datos generados describan de manera apropiada el estado de la calidad del aire, por ello, la operación del programa de monitoreo requiere también de metodologías y estándares para la medición, así como de un programa continuo de aseguramiento de la calidad (Dirección de Monitoreo Atmosférico de la CDMX, n.d.-a).

1.5.1 EVOLUCIÓN DEL MONITOREO DE CONTAMINANTES EN MÉXICO

La Ciudad de México, como parte de la Zona Metropolitana del Valle de México, es una urbe que se encuentra en constante crecimiento. La necesidad de monitorear los contaminantes en el aire surge entre las décadas de los años 40 y 50 por una disminución en la visibilidad en la urbe. Es en esta época en la que se presenta un importante crecimiento industrial en la capital del país (Haber et al., 1993). De la misma manera, la

tasa de crecimiento poblacional del año 1940 al 1950 fue de 5.5, la más grande registrada históricamente (INEGI, 2021).

Son estos factores los que contribuyeron a que la visibilidad se redujera de un rango inicial de 4 a 10 kilómetros a un rango de 2 a 4 km. Consecuentemente, la Dirección de Higiene Industrial de la Secretaría de Salubridad y Asistencia comenzó con las primeras investigaciones en 1950 con el fin de cuantificar las concentraciones de contaminantes en el aire.

Después de la publicación de estudios y otras investigaciones, es en la siguiente década cuando finalmente se realiza la instalación de las primeras 4 estaciones de monitoreo de contaminantes atmosféricos que medían material particulado, SO₂, polvo sedimentable y acidez. En 1967 la Organización Panamericana de la Salud realiza la instalación de la “Red Panamericana de Muestreo Normalizado de la Contaminación del Aire (REDPANARE)”, aportando 10 estaciones de monitoreo atmosférico para la Ciudad de México.

Más adelante, se incorpora la “Red Computarizada Automática de Monitoreo Atmosférico del Valle de México” y se añaden 12 estaciones adicionales. Los avances tecnológicos también fomentaron el estudio de los contaminantes atmosféricos. A esta acción se suma el Instituto de Ciencia Aplicada de la UNAM desarrollando estudios de muestreo y análisis de contaminantes atmosféricos, incluyendo material particulado, dióxido de azufre, monóxido de carbono y ozono. Posteriormente, se inauguró el Centro de Ciencias de la Atmósfera de la UNAM en 1977 (Instituto de Ciencias de la Atmósfera y Cambio Climático, 2021).

En 1985, la Secretaría de Desarrollo Urbano y Ecología (SEDUE) adquirió 25 estaciones de monitoreo ambiental, 2 radares sónicos y 10 torres meteorológicas. Este nuevo sistema sería conocido hasta la actualidad como la Red Automática de Monitoreo Atmosférico (RAMA). También se encontraba en funcionamiento una red manual con 19 estaciones de monitoreo. En ambas redes, las estaciones contaban con características diferentes para medir diversos contaminantes como SO₂, CO, O₃, NO₂, NO_x, HNM y H₂S; algunas de ellas también

contaron con la capacidad de monitorear temperatura ambiente, humedad relativa, dirección y velocidad del viento. De forma paralela, ya operaba la Red Manual (REDMA) con 19 estaciones monitoreando partículas suspendidas totales.

En la siguiente década se incorporaron más de 40 estaciones para la medición de diferentes contaminantes y también de radiación. Como parte del crecimiento de las redes de monitoreo, en el 2000 se integró el Sistema de Monitoreo Atmosférico de la Ciudad de México con el fin de unificar la RAMA, la Red de Meteorología y Radiación Solar (REDMET) y la Red de Depósito Atmosférico (REDDA).

Para 2006, el SIMAT tenía en operación 48 estaciones de monitoreo, 36 ubicadas en la Ciudad de México, y 11 en el Estado de México, con un total de 175 equipos automáticos y 39 equipos manuales, 23 de los cuales son para partículas suspendidas y 16 para el depósito atmosférico. Con el paso del tiempo, se retiraron 10 estaciones de monitoreo que dejaron de cumplir los objetivos de calidad del aire.

En el Sistema de Monitoreo Atmosférico de la Ciudad de México (SIMAT) se realiza de manera continua la medición de gases, partículas suspendidas y parámetros meteorológicos, así como el muestreo y análisis de partículas suspendidas y agua de lluvia (depósito húmedo).

1.5.2 NORMATIVIDAD

En México, como parte de la protección de la salud pública, el gobierno federal establece los estándares para el cumplimiento de límites permisibles de niveles de contaminantes atmosféricos, criterios que deben ser acatados en todo el país. Publicadas en las Normas Oficiales Mexicanas (NOM), se tienen vigentes dos tipos de normas: las NOM de salud ambiental y las NOM técnicas. En las primeras se establecen los límites permisibles para los contaminantes criterio y en las segundas los métodos de medición de estos.

Las NOM de salud ambiental vigentes son las que se muestran en la siguiente tabla:

Tabla 1.3 NOM de salud ambiental vigentes dictadas por la Secretaría de Salud (SSA)

(Dirección de Monitoreo Atmosférico de la CDMX, n.d.-c)

Contaminante	NOM	Publicación	Descripción
Dióxido de azufre (SO ₂)	NOM-022-SSA1-2019	20/08/2019	0.075 ppm, promedio aritmético de 3 años consecutivos de los percentiles 99 anuales como promedio horario 0.040 ppm, máximo promedio de 24 horas
Monóxido de carbono (CO)	NOM-021-SSA1-2021	29/10/2021	26 ppm, promedio horario 9 ppm, promedio móvil de 8 horas
Dióxido de nitrógeno (NO ₂)	NOM-023-SSA1-2021	27/10/2021	0.106 ppm, promedio horario 0.021 ppm, promedio anual
Ozono (O ₃)	NOM-020-SSA1-2021	28/10/2021	Años 2022-2023: 0.090 ppm, promedio horario 0.065 ppm, promedio móvil de 8 horas Años 2024-2025: 0.090 ppm, promedio horario 0.060 ppm, promedio móvil de 8 horas A partir de 2026: 0.090 ppm, promedio horario 0.051 ppm, promedio móvil de 8 horas
Partículas menores a 10 µm (PM ₁₀)	NOM-025-SSA1-2021	27/10/2021	Años 2022-2023: 70 µg/m ³ , promedio de 24 horas y 36 µg/m ³ , promedio anual Años 2024-2025: 60 µg/m ³ , promedio de 24 horas y 28 µg/m ³ , promedio anual A partir de 2026: 50 µg/m ³ , promedio de 24 horas y 20 µg/m ³ , promedio anual
Partículas menores a 2.5 µm (PM _{2.5})	NOM-025-SSA1-2021	27/10/2021	Años 2022-2023: 41 µg/m ³ , promedio de 24 horas y 10 µg/m ³ , promedio anual Años 2024-2025: 33 µg/m ³ , promedio de 24 horas y 10 µg/m ³ , promedio anual A partir de 2026: 25 µg/m ³ , promedio de 24 horas y 10 µg/m ³ , promedio anual
Plomo (Pb)	NOM-026-SSA1-2021	29/10/2021	0.5 µg/m ³ , promedio anual obtenido mediante muestreos manuales de PM ₁₀

Las NOM técnicas vigentes son las siguientes:

Tabla 1.4 NOM técnicas vigentes dictadas por 'la Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT) (Dirección de Monitoreo Atmosférico de la CDMX, n.d.-c)

Contaminante	NOM	Publicación	Descripción
Dióxido de azufre (SO ₂)	NOM-038-SEMARNAT-1993	18/10/1993	Método equivalente: fluorescencia ultravioleta
Monóxido de carbono (CO)	NOM-034-SEMARNAT-1993	18/10/1993	Método de referencia: absorción en el infrarrojo
Dióxido de nitrógeno (NO ₂)	NOM-037-SEMARNAT-1993	18/10/1993	Método de referencia: quimioluminiscencia en fase gaseosa
Ozono (O ₃)	NOM-036-SEMARNAT-1993	18/10/1993	Método equivalente: fotometría ultravioleta
Partículas suspendidas totales (PST)	NOM-035-SEMARNAT-1993	18/10/1993	Muestreo: alto volumen Análisis: gravimetría
Partículas menores a 10 µm (PM ₁₀)	No se cuenta con una NOM de métodos de medición, sin embargo, se considera el método equivalente que recomienda la US EPA.		Gravimetría o atenuación de radiación beta
Partículas menores a 2.5 µm (PM _{2.5})	No se cuenta con una NOM de métodos de medición, sin embargo, se considera el método equivalente que recomienda la US EPA.		Gravimetría o atenuación de radiación beta
Plomo (Pb)	No se cuenta con una NOM de métodos de medición.		

Adicionalmente, se tienen otras normas que regulan la operación de los sistemas de monitoreo, la obtención y comunicación del Índice de la Calidad del Aire y Riesgos a la Salud y los requisitos para elaborar este último.

Tabla 1.5 NOM que regulan la operación de los sistemas de monitoreo de la calidad del aire, su comunicación y requisitos para la elaboración del índice de Calidad en la Ciudad de México (Dirección de Monitoreo Atmosférico de la CDMX, n.d.-c)

Norma	Publicación	Descripción
NOM-156-SEMARNAT-2012	16/07/2012	Establecimiento y operación de sistemas de monitoreo de la calidad del aire
NOM-172-SEMARNAT-2019	20/11/2019	Lineamientos para la obtención y comunicación del Índice de Calidad del Aire y Riesgos a la Salud
NADF-009-AIRE-2017	14/11/2018	Establece los requisitos para elaborar el Índice de Calidad del Aire en la Ciudad de México.

Cabe aclarar que, en caso de no existir una NOM para un criterio contaminante, se utiliza la recomendación por parte de la Agencia de Protección Ambiental de Estados Unidos (US EPA), en la cual también se hace referencia para establecer los métodos de las NOM técnicas (Dirección de Monitoreo Atmosférico de la CDMX, n.d.-c).

Será de principal interés para este estudio la NOM-025-SSA1-2021 que establece los valores límite del contaminante $PM_{2.5}$ en unidades de microgramo por cada metro cúbico con valores de un promedio anual permisible, así como valores de un promedio en un periodo de 24 horas. En esta norma, se presentan valores límite diferentes que se harán válidos en periodos de dos años a partir de la entrada en vigor de la norma (Secretaría de Salud, 2021).

1.5.3 ESTACIONES DE MONITOREO ATMOSFÉRICO

Las estaciones de monitoreo de donde se obtuvo la información necesaria para desarrollar este trabajo corresponden a la Red Automática de Monitoreo Atmosférico mencionada anteriormente como subsistema del SIMAT. La RAMA, conformada por 34 estaciones de monitoreo distribuidas en la ZMVM y un laboratorio para su mantenimiento y calibración, cuenta con la capacidad de generar información continua de diferentes contaminantes criterio como PM_{10} , $PM_{2.5}$, dióxido de azufre, monóxido de carbono, dióxido de nitrógeno y ozono.

Debido a la antigüedad de la RAMA y su constante crecimiento, no todas las estaciones cuentan con la instrumentación necesaria para medir todos los diferentes contaminantes. En la tabla 1.7 se enlistan las estaciones de monitoreo que fueron de especial interés para el desarrollo de este trabajo, es decir, las estaciones que registran concentraciones de $PM_{2.5}$. En la figura 1.10 se observa la ubicación de la totalidad de estaciones que conforman la RAMA y se destacan con un contorno las estaciones que miden concentraciones de $PM_{2.5}$

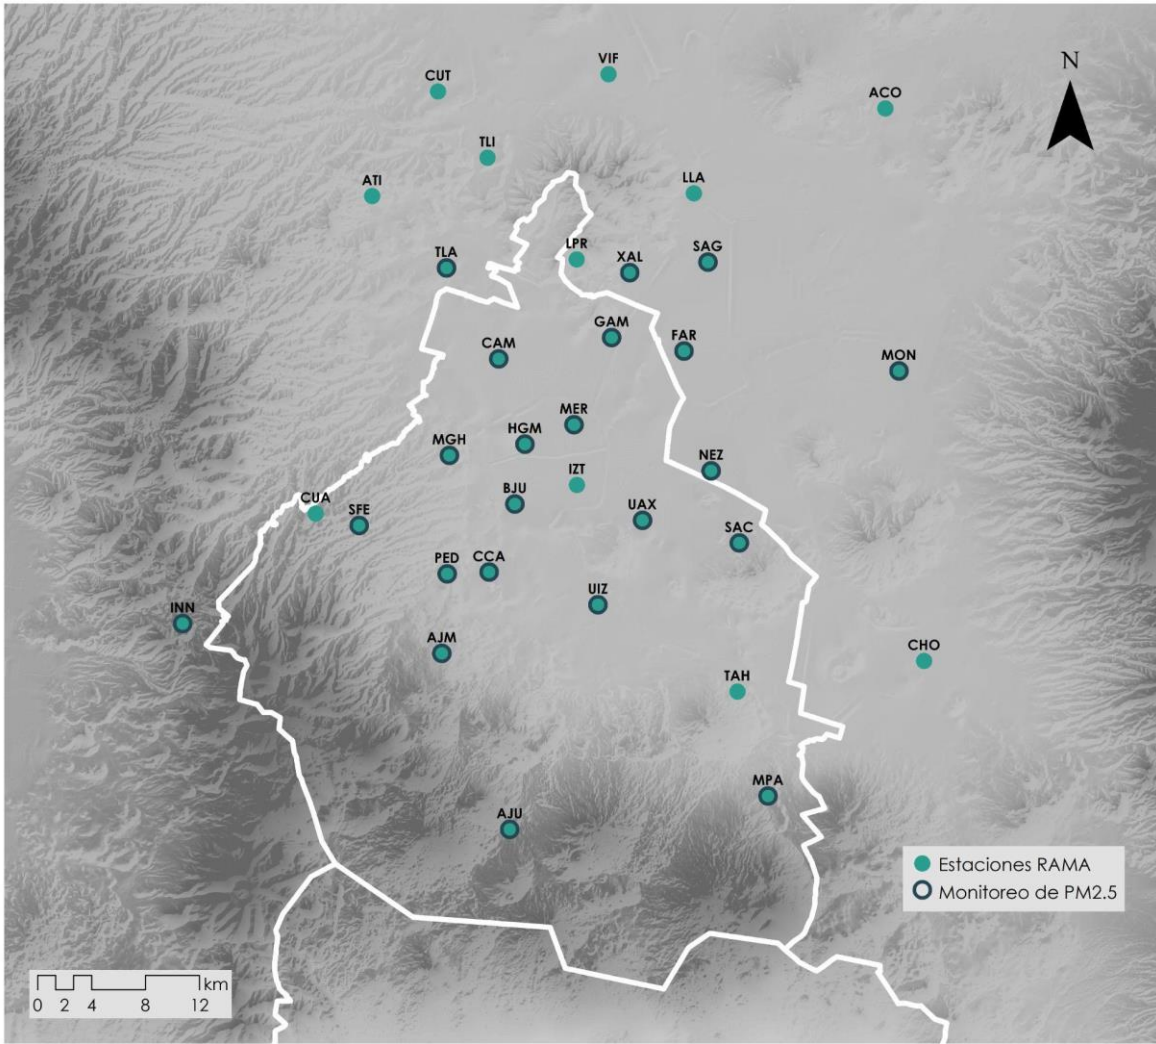


Figura 1.12 Localización de las estaciones de la Red Automática de Monitoreo Atmosférico en la Ciudad de México

Tabla 1.6 Coordenadas de las estaciones de la Red Automática de Monitoreo Atmosférico en la Ciudad de México (Dirección de Monitoreo Atmosférico de la CDMX, n.d.-b)

Nombre	Clave	Latitud	Longitud
Acolman	ACO	19.6355	-98.912
Ajusco Medio	AJM	19.2721	-99.2077
Ajusco	AJU	19.1547	-99.1625
Atizapán	ATI	19.577	-99.2541
Benito Juárez	BJU	19.3716	-99.159
Camarones	CAM	19.4684	-99.1698
Centro de Ciencias de la Atmósfera	CCA	19.3262	-99.1761
Chalco	CHO	19.2669	-98.8861
Cuajimalpa	CUA	19.3653	-99.2917
Cuautitlán	CUT	19.6468	-99.2102
FES Aragón	FAR	19.4737	-99.0462
Gustavo A. Madero	GAM	19.4827	-99.0945
Hospital General de México	HGM	19.4116	-99.1522
Investigaciones Nucleares	INN	19.292	-99.3805
Iztacalco	IZT	19.3844	-99.1176
Los Laureles	LLA	19.5788	-99.0396
La Presa	LPR	19.5347	-99.1177
Merced	MER	19.4246	-99.1196
Miguel Hidalgo	MGH	19.4041	-99.2026
Montecillo	MON	19.4604	-98.9029
Milpa Alta	MPA	19.1769	-98.9902
Nezahualcóyotl	NEZ	19.3937	-99.0282
Pedregal	PED	19.3251	-99.2041
San Agustín	SAG	19.533	-99.0303
Santiago Acahualtepec	SAC	19.3456	-99.0094
Santa Fe	SFE	19.3574	-99.2629
Tláhuac	TAH	19.2465	-99.0106
Tlalnepantla	TLA	19.5291	-99.2046
Tultitlán	TLI	19.6025	-99.1772
UAM Iztapalapa	UAX	19.3608	-99.0739
UAM Xochimilco	UIZ	19.3044	-99.1036
Villa de las Flores	VIF	19.6582	-99.0966
Xalostoc	XAL	19.526	-99.0824

1.5.4 ESTACIONES METEOROLÓGICAS

El principal organismo encargado de la meteorología en México es el Servicio Meteorológico Nacional, que reporta el estado del tiempo a nivel nacional de forma continua (Servicio Meteorológico Nacional, 2021). A pesar de existir este organismo, se optó por utilizar información proveniente del Programa de Estaciones Meteorológicas del Bachillerato Universitario, un programa institucional de la Universidad Nacional Autónoma de México que proporciona una base de datos histórica de 15 estaciones meteorológicas en la Ciudad de México que registran datos de temperatura, humedad relativa, rapidez y dirección del viento sostenido, rapidez y dirección de rachas, presión, precipitación, radiación solar e índice y dosis ultravioleta cada 30 minutos (PEMBU, 2022).

1.5.5 AIRE Y SALUD

La calidad del aire se ha vuelto un tema de preocupación global en las últimas décadas. El deterioro de la calidad del aire, producto de la presencia de contaminantes atmosféricos, tiene consecuencias negativas en el medio ambiente y por lo tanto en la salud humana. Diariamente en la Ciudad de México, como resultado de las actividades diarias de sus habitantes y la industria, se generan una importante cantidad de sustancias que modifican la composición natural del aire. La quema de combustibles fósiles para la generación de energía para consumo doméstico e industrial, el transporte, entre otras actividades humanas y la emisión de fuentes naturales, producen miles de toneladas de contaminantes que se emiten diariamente a la atmósfera (Dirección de Monitoreo Atmosférico de la CDMX, n.d.-a).

Estudios han demostrado que la exposición a contaminantes atmosféricos tiene una relación con el aumento de enfermedades respiratorias y cardiovasculares, siendo el material particulado uno de los contaminantes responsables principales. Se ha establecido que las partículas finas, concretamente las de un diámetro de 2.5 micrómetros ($PM_{2.5}$) son más perjudiciales que las de diámetro igual o inferior a 10 micrómetros (PM_{10}) (Villar-Vidal et al., 2014). El $PM_{2.5}$ se ha asociado con enfermedades respiratorias agudas y crónicas, como

la neumonía y la bronquitis crónica, y enfermedades cardiovasculares, como la cardiopatía coronaria, la insuficiencia cardíaca congestiva y la muerte prematura. En México, las estimaciones corresponden a cerca de 29,000 muertes y casi 558,000 años de vida ajustados por discapacidad atribuibles a la mala calidad del aire (Secretaría de Salud, 2021). Muchos estudios epidemiológicos han confirmado la relación entre el aumento de la mortalidad o la morbilidad y las concentraciones de PM_{2,5} (Miller & Xu, 2018). En realidad, la exposición humana al PM_{2,5} está influenciada por la exposición en el interior y en el exterior, así como por actividades personales como fumar, tener una mascota o simplemente moverse por la casa, lo que provoca la resuspensión de partículas, pero no se puede negar el impacto de la calidad del aire en la salud humana (Wheeler et al., 2011).

En el área norte de la ciudad se ubican múltiples complejos industriales, que son notables emisores de contaminantes, por lo que, al fluir el viento de norte a sur, se produce el fenómeno de transporte de contaminantes hacia el centro y las zonas residenciales del sur de la ciudad. Las actividades humanas son las fuentes principales de emisión de PM_{2,5} en la zona de estudio, entre las más significativas se encuentran las actividades industriales, el transporte, el tratamiento de agua, los tiraderos de basura y rellenos sanitarios (Marr et al., 2004). La altitud a la que se encuentra la Ciudad de México provoca que el aire contenga 23% menos oxígeno que el aire que se respira a nivel del mar, esto provoca que, para que una persona obtenga una cantidad equivalente de oxígeno, es necesario inhalar más aire, provocando una exposición a una dosis más alta de contaminantes a lo largo del tiempo.

1.6. OBJETIVOS

1.6.1 OBJETIVO GENERAL

Comparación del desempeño multitemporal de un modelo computacional implementado para la estimación de concentraciones del contaminante atmosférico $PM_{2.5}$ a partir de técnicas de percepción remota y aplicación de redes neuronales artificiales en la Ciudad de México.

1.6.2 OBJETIVOS PARTICULARES

- Dar continuidad al trabajo de investigación del proyecto SECITI/o89/2017 "Desarrollo de modelos para la estimación de material particulado suspendido de la Zona Metropolitana de la Ciudad de México mediante el uso de imágenes satelitales e información geoespacial" y la publicación de la tesis "Incorporación de datos meteorológicos en la modelación de material particulado $PM_{2.5}$ con redes neuronales en la Ciudad de México" del ingeniero Francisco Andree Ramírez Casas (Ramírez Casas, 2020).
- Generar mapas de concentraciones de $PM_{2.5}$ en temporada de lluvias y de estiaje en la Ciudad de México para los años 2016, 2018 y 2019.
- Análisis de los datos generados a partir de la implementación de un modelo para la estimación de contaminantes atmosféricos.
- Comparar los datos estimados por el modelo predictivo contra los reportados por la Red Automática de Monitoreo Atmosférico en el periodo de análisis de estudio.

1.7. HIPÓTESIS

Al realizar un análisis multitemporal del desempeño del modelo de estimación del contaminante $PM_{2.5}$ en la Ciudad de México se tendrán mejores resultados al evaluar el error cuadrático medio en la temporada de lluvias debido a la incorporación de variables meteorológicas.

2. ESTADO DEL ARTE EN LA INVESTIGACIÓN PARA LA ESTIMACIÓN DE CONTAMINANTES ATMOSFÉRICOS

Existe una amplia variedad de investigaciones enfocadas a la generación y evaluación de modelos para la estimación de concentraciones de material particulado utilizando percepción remota. La necesidad de monitorear las concentraciones de contaminantes atmosféricos por cuestiones de salud ha cobrado mayor importancia en las grandes urbes del mundo. Distintos investigadores han presentado modelos obtenidos mediante diversos métodos.

En 2004, Tolga Elbir publicó la investigación "GIS-based decision support system for the estimation, visualization and analysis of air pollution in big cities of Turkey" utilizando modelos de dispersión CALPUFF, mapas digitales y bases de datos para estimar emisiones de contaminantes atmosféricos y gases de efecto invernadero en ciudades de Turquía (Hamzelo et al., 2015).

Un estudio llevado a cabo en diferentes ciudades fue publicado en 2006 por investigadores del Departamento de Ciencias Atmosféricas de la Universidad de Alabama con el título "Satellite remote sensing of particulate matter and air quality assessment over global cities". El Dr. Pawan Gupta y otros colaboradores recopilaron datos de Espesor Óptico de Aerosol (AOT) capturados por los satélites Aqua y Terra de la NASA, además de registrar datos de concentraciones de masa de $PM_{2.5}$ medidos en campo para evaluar la calidad del aire en 26 ubicaciones en Sidney, Delhi, Hong Kong, Nueva York y Suiza. El estudio demostró una fuerte correlación entre los valores de AOT capturados por los sensores satelitales y los valores de concentraciones de $PM_{2.5}$ obtenidos en campo. Cabe aclarar que se observó que considerar variables como la humedad relativa, la nubosidad, la altura de la capa de mezcla y la concentración de aerosol fue esencial para obtener dicha correlación (Gupta et al., 2006).

En 2010 se publicó el artículo de un estudio en Arabia Saudita por Nadzri Othman y otros investigadores titulado "Estimating particulate matter concentration over arid region using

satellite remote sensing: A case study in Makkah, Saudi Arabia” en el que se hizo uso de imágenes capturadas por el satélite Landsat 7 y presenta modelos de algoritmo multiespectral para estimar concentraciones de material particulado menor a 10 micrómetros comparando los resultados con mediciones registradas en campo (Othman et al., 2010). Este estudio se encuentra citado constantemente por otros investigadores por su metodología para el desarrollo de modelos de estimación de material particulado. Los resultados obtenidos en este estudio mostraron que las raíces de los errores cuadráticos medios son de alrededor de $10 \mu\text{g}/\text{m}^3$ excepto en un caso que asciende a más de $22 \mu\text{g}/\text{m}^3$.

Un estudio que utiliza modelos de regresiones lógicas es el publicado en 2013 llamado “Comparison of remote sensing and fixed-site approaches for examining air pollution and health national study population” en donde se vuelve a mostrar una correlación considerable entre los datos reportados mediante monitoreo terrestre y aquellos obtenidos mediante percepción remota en Canadá (Prud’homme et al., 2013).

Posteriormente, en 2017 Ishan Saraswat publicó el artículo “Estimation of PM_{10} concentration from Landsat 8 OLI satellite imagery over Delhi, India” haciendo referencia a la metodología de Othman para desarrollar modelos de estimación de PM_{10} en la ciudad de Delhi. Saraswat utilizó una base de datos más grande que Othman, por lo que su modelo es considerado de mayor fiabilidad. Este estudio coincide con el presente trabajo en el uso de imágenes satelitales de Landsat 8. En el artículo se presentan 10 modelos de estimación del contaminante usando diferentes combinaciones de bandas del satélite y se obtuvo un promedio de las RMSE superior a $22 \mu\text{g}/\text{m}^3$ (Saraswat et al., 2017).

Además de estas publicaciones, cabe mencionar aquellas investigaciones en las que se desarrollaron modelos a partir de redes neuronales como es el caso del utilizado en este trabajo. En 2016, Yuanyuan Chu y sus colaboradores llevaron a cabo una revisión de 116 artículos en los que se presentaron diferentes modelos de estimación de $\text{PM}_{2.5}$ obtenidos con diversos métodos a partir de datos de profundidad óptica de aerosoles (Zhang et al., 2018). Chu indica que los modelos que se publicaron con más frecuencia fueron: regresión

lineal múltiple, modelos de efecto mixto, modelos de transporte químico y regresiones con muestreo espacial. En cuanto a modelos desarrollados con redes neuronales artificiales, Chu concluye que deben ser investigados con mayor detalle puesto que reportan valores de R_2 muy variados con valores entre 0.03 y 0.85. Posterior a este estudio, en 2017 publicó Nuru Kamarul Zaman y Hao Lyu en 2018 modelos obtenidos con redes neuronales para la estimación de material particulado en ciudades de Asia (Lyu et al., 2018). Kamarul Zaman reportó valores de RMSE de $11.61 \mu\text{g}/\text{m}^3$ en estimaciones de PM_{10} (Kamarul Zaman et al., 2017), mientras que Lyu publicó valores de $55.43 \mu\text{g}/\text{m}^3$ para estimaciones de $\text{PM}_{2.5}$.

Por último, las publicaciones desarrolladas como parte del proyecto SECITI/089/2017 "Desarrollo de modelos para la estimación de material particulado suspendido de la Zona Metropolitana de la Ciudad de México mediante el uso de imágenes satelitales e información geoespacial" del cual forma parte el presente trabajo, son las de Pablo Ángeles y Francisco Ramírez Casas. Ambos estudios para la Ciudad de México desarrollan modelos de estimación de $\text{PM}_{2.5}$ obtenidos mediante el uso de redes neuronales artificiales. Ángeles presenta un modelo sin incorporar variables meteorológicas obteniendo un valor de R_2 de 0.617 (Ángeles Salto, 2019), mientras que Ramírez Casas incorpora la temperatura, humedad relativa y precipitación acumulada a 1, 3 y 5 días para obtener tres modelos, de los cuales el mejor obtuvo un coeficiente de correlación al aplicar los datos de prueba de 0.785 (Ramírez Casas, 2020).

3. METODOLOGÍA PARA EJECUTAR EL MODELO PREDICTIVO

3.1. FUENTES DE INFORMACIÓN

3.1.1 IMÁGENES SATELITALES

Las imágenes capturadas por el satélite Landsat 8 se encuentran disponibles para su descarga en el sitio web del Servicio Geológico de los Estados Unidos, o USGS por sus siglas en inglés. Esta organización cuenta con una plataforma de consulta llamada EarthExplorer, en donde se permite la consulta de grupos de datos de distintos satélites. Para obtener las imágenes correspondientes a la zona de estudio, es necesario seleccionar la trayectoria o ruta y fila del satélite (path/row), en este caso el valor es 26/47 del sistema de referencia WRS-2. En su trayectoria, el satélite Landsat 8 captura información sobre la Ciudad de México una vez por semana a las 11:00 AM en el horario de la capital del país.

Se obtienen archivos que contienen información de reflectancia superficial (SR) de las diferentes bandas espectrales que captan los sensores del satélite, además de la reflectancia de tope de atmósfera o Top of Atmosphere Reflectance (TOA) con la resolución proporcionada por el satélite que asigna valores de reflectancia a una superficie de 30 metros por 30 metros.

3.1.2 DATOS METEOROLÓGICOS

Las variables meteorológicas utilizadas en el desarrollo de este trabajo corresponden a la humedad relativa y a la precipitación acumulada a uno, tres y cinco días. Estos datos meteorológicos se registran por las estaciones a cargo del Programa de Estaciones Meteorológicas del Bachillerato Universitario de la UNAM.

Las estaciones meteorológicas registran cada 30 minutos datos de temperatura, humedad relativa, rapidez y dirección del viento sostenido, rapidez y dirección de rachas, presión, precipitación, radiación solar e índice y dosis ultravioleta. Estos registros se pueden

descargar desde el sitio web del PEMBU con los datos recopilados durante un año por cada estación.

3.1.3 REGISTRO DE ESTACIONES DE MONITOREO AMBIENTAL

Las concentraciones del contaminante atmosférico $PM_{2.5}$ se encuentran disponibles para su consulta en los registros de contaminantes de las estaciones de la Red Automática de Monitoreo Atmosférico. La RAMA proporciona reportes anuales que contienen datos de concentraciones de ocho contaminantes en las diferentes estaciones de monitoreo registrados en intervalos de tiempo de una hora.

3.1.4 MODELOS DE ESTIMACIÓN DE $PM_{2.5}$

El modelo matemático para la estimación de $PM_{2.5}$ en la atmósfera de la CDMX forma parte de los modelos no lineales obtenidos en el trabajo del Ing. Andree Ramírez Casas en la tesis “Incorporación de datos meteorológicos en la modelación del material particulado $PM_{2.5}$ con redes neuronales en la Ciudad de México”. Los modelos obtenidos incorporan reflectancias atmosféricas (RA) y de tope de atmósfera correspondientes a las bandas 1 a 7 de los sensores del satélite. En dicha publicación, se presentan los 6 modelos con mejor coeficiente de determinación (R^2) de 200 diferentes modelos que se obtuvieron haciendo uso de una red neuronal (Ramírez Casas, 2020), de los cuales la mitad incorporaron variables meteorológicas en los valores de entrada.

La red neuronal fue desarrollada utilizando el software R con la adición de Keras, una biblioteca de redes neuronales de código abierto ejecutada sobre Tensorflow. Los modelos tienen una arquitectura “fully connected”, es decir que cada neurona está conectada a todas las neuronas de la siguiente capa y la información fluye de izquierda a derecha. La red modelada está conformada por cinco capas, una capa de entrada que consta de 18 nodos, tres capas ocultas con 240, 120 y 60 nodos respectivamente y una capa de salida que corresponde al valor estimado de concentración de $PM_{2.5}$.

Como resultado de la tesis de Ramírez Casas, se determinó que los modelos que incorporan humedad relativa y precipitación acumulada como variables meteorológicas mejora la capacidad predictiva de los modelos con excepción de algunas zonas de la CDMX. Los modelos fueron proporcionados por SECTEII para el desarrollo de este trabajo.

3.2. PROCEDIMIENTOS

En este apartado se describen las herramientas y los procedimientos que se utilizaron para el procesamiento de la información previamente mencionada. Se hizo uso principalmente del lenguaje de programación R en la plataforma RStudio para programar scripts y así poder extraer y posteriormente manipular la información y obtener los resultados que se presentan en el siguiente apartado.

3.2.1 SELECCIÓN DEL MODELO A EVALUAR

De los seis modelos publicados por Ramírez Casas, solamente tres de ellos incorporan variables meteorológicas para realizar estimaciones del contaminante $PM_{2.5}$. Para el desarrollo de este trabajo, se optó por utilizar únicamente el modelo que resultó con un valor de R^2 igual a 0.785, el más alto entre los tres modelos mencionados.

3.2.2 SELECCIÓN DE FECHAS A COMPARAR

Debido a la inclusión de la humedad relativa y la precipitación acumulada como variables meteorológicas, se seleccionaron las temporadas de estiaje y de lluvias para realizar la comparación del desempeño del modelo de estimación en distintas épocas del año.

Otro factor por considerar en la selección de las fechas para la descarga de las imágenes satelitales fue la cobertura de nubes sobre la Ciudad de México. La presencia de nubes sobre la zona de estudio no permite la estimación de $PM_{2.5}$ ya que el valor de reflectancias que se utiliza debe ser el que se encuentra en la superficie. Utilizando la herramienta Google Earth Engine, una plataforma para el análisis científico y la visualización de conjuntos de datos geoespaciales desde donde se puede acceder a la base de datos del satélite Landsat 8

(Gorelick et al., 2017), se programó un script en el editor de código code.earthengine.google.com, que es un IDE basado en la web para la API JavaScript de Earth Engine, aplicando la función “filterMetadata” al atributo “CLOUD_COVER” para identificar las imágenes con menor nubosidad en los rangos de las fechas deseadas, posteriormente se hizo un segundo filtrado manual para corroborar que las imágenes no presentaran cobertura de nubes sobre la CDMX. El listado final de fechas que se analizaron en este trabajo se encuentra en la tabla 3.1.

Tabla 3.1 Fechas seleccionadas para el análisis de datos

Año	Temporada	Fecha
2016	Estiaje	21 de enero
	Lluvias	20 de mayo
2018	Estiaje	10 de enero
	Lluvias	5 de julio
2019	Estiaje	29 de enero
	Lluvias	8 de julio

3.2.3 PROCESAMIENTO DE LA INFORMACIÓN DE REFLECTANCIAS

La información requerida para ejecutar el modelo consiste en datos de reflectancias de tope de atmósfera y reflectancia atmosférica para las bandas 1 a 7 del sensor del satélite. Se mencionó con anterioridad que la fuente de información de las imágenes satelitales proporciona la reflectancia de tope de atmósfera y la reflectancia superficial, por lo que un procesamiento fue necesario para obtener la reflectancia atmosférica. Esta reflectancia puede ser obtenida mediante la operación de restar la reflectancia atmosférica a la reflectancia de tope de atmósfera. Para obtener los valores de RA, se utilizó el lenguaje de programación R mencionado anteriormente con la función “raster” para cargar la información de TOA y SR por cada banda en formato de imagen “.tif”. A continuación, se realizó la resta de los valores y este valor se le asignó de forma ordenada a un objeto de tipo “data frame” para finalmente utilizar la función “write.csv” y escribir el archivo que contiene el valor de reflectancia atmosférica por cada banda.

3.2.4 OBTENCIÓN DE DATOS METEOROLÓGICOS DEL PEMBU

Para obtener los datos de humedad relativa y precipitación acumulada de los datos proporcionados por el PEMBU, se programó un script que consistió en cargar los archivos de todos los registros de un año de cada estación en formato “.csv” usando la función “read.csv”. Utilizando la función “subset”, se extrajeron los valores de humedad relativa y precipitación a las 11:00 AM de una de las fechas de interés con el fin de coincidir exactamente con la hora en la que se toman las imágenes satelitales por parte del Landsat 8. Debido a que los archivos con los datos meteorológicos contienen únicamente la precipitación registrada a una hora del día, fue necesario obtener la precipitación acumulada como la suma de las precipitaciones 72 y 120 horas antes para obtener la precipitación acumulada a tres y cinco días. Finalmente, con la función “write.csv” se escribió el archivo con los datos que requiere el modelo de estimación que se utilizará más adelante.

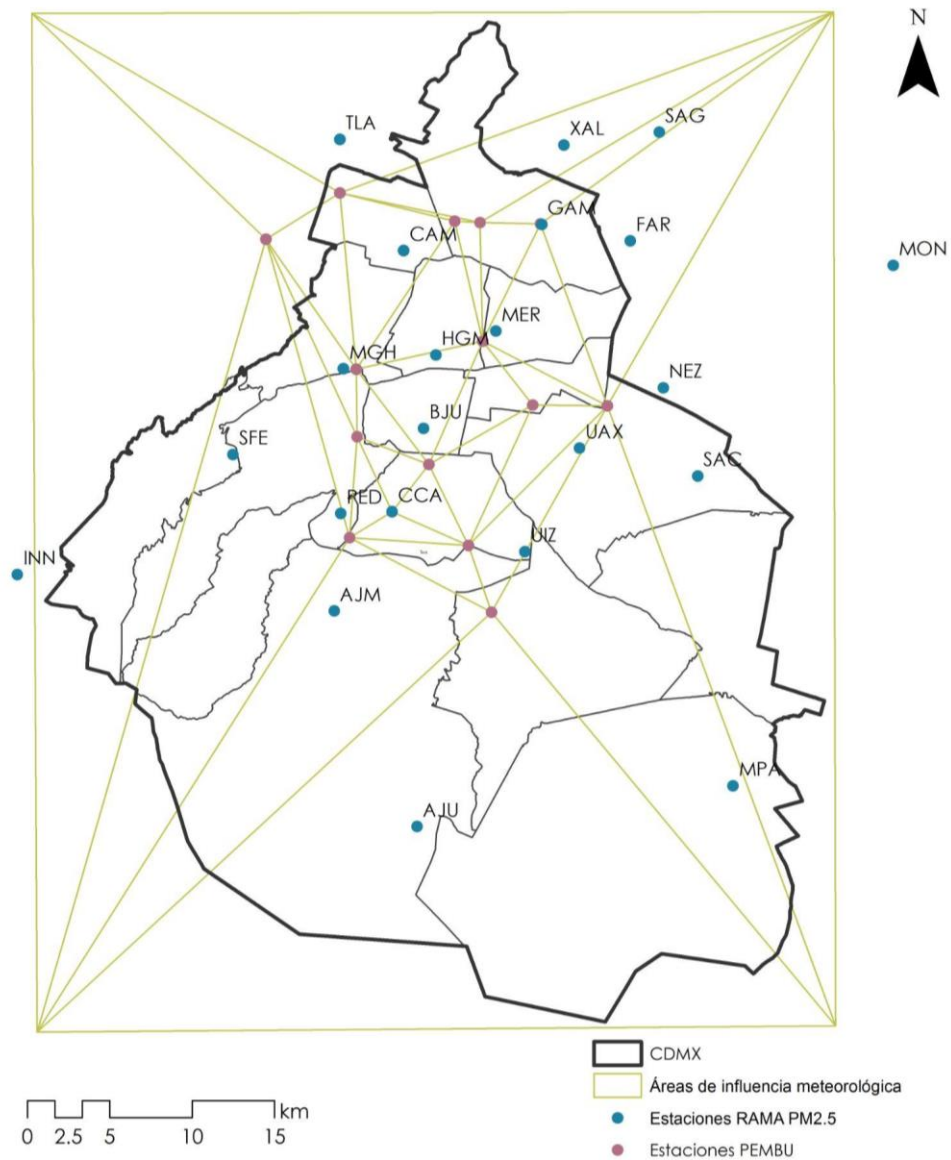


Figura 3.1 Estaciones de la RAMA y PEMBU

El siguiente paso consistió en asignar los valores procesados a las áreas de influencia correspondientes. Siguiendo los requerimientos de los modelos predictivos que se utilizaron en este trabajo (Ramírez Casas, 2020), se utilizó la triangulación de Delaunay utilizando las estaciones meteorológicas como vértices y se asignaron los valores promedio de humedad relativa y precipitación acumulada a las áreas de influencia resultantes. Este

procedimiento se repitió de la misma manera para el resto de las fechas a analizar para este trabajo.

3.2.5 UNIFICACIÓN DE DATOS

Los datos meteorológicos y de reflectancias fueron procesados por separado. Para continuar con los procedimientos requeridos para ejecutar el modelo predictivo, se crearon documentos que contuvieran ambos datos por cada fecha a analizar. Programando en R y utilizando la función “merge”, se obtuvo un archivo con los valores de reflectancia atmosférica, reflectancia de tope de atmósfera, humedad relativa, precipitación acumulada a uno, tres y cinco días para cada fecha.

3.2.6 APLICACIÓN DEL MODELO Y ELABORACIÓN DE MAPAS DE CONCENTRACIONES DE $PM_{2.5}$

El procedimiento para obtener predicciones a partir de los datos procesados por cada fecha de interés, consistió en correr un programa escrito en el lenguaje de programación R, donde primero se carga el modelo proporcionado en formato “.hdf5”. Posteriormente, se subieron los archivos con la base de datos de reflectancias y meteorología para así aplicar la función “predict” y obtener los valores de concentración de $PM_{2.5}$ que el modelo predice a partir de los datos iniciales.

Una vez que se obtuvieron los valores, se continuó programando código para manipular los datos y escribir archivos ráster para la generación de mapas con los datos predichos. Utilizando la función “readShapePoints”, se cargó el archivo con la información para delimitar el espacio georreferenciado donde se asignaron los valores obtenidos coincidiendo con la resolución de los sensores del satélite Landsat 8 de 30 metros por 30 metros sobre la superficie.

Con la función “rasterize” y “crs” se asignaron los valores predichos de cada fecha al área de influencia correspondiente en el sistema de referencia de coordenadas, obteniendo un archivo de formato “.tif”. De esta forma, y conociendo los puntos en donde se encuentran

las estaciones que registran el contaminante atmosférico $PM_{2.5}$ de la RAMA, se hizo una extracción puntual de los datos predichos para posteriormente realizar la comparación entre los valores reportados en campo.

Finalmente, en el software libre QGIS se cargó el archivo “.tif” con los valores predichos por el modelo en el área de estudio para finalmente tener una representación visual de las concentraciones de $PM_{2.5}$ en toda la ciudad mediante la asignación de una rampa de colores donde se fijó un valor máximo de $75 \mu\text{g}/\text{m}^3$ y un valor mínimo de cero.

4. RESULTADOS Y DISCUSIÓN

4.1. DESEMPEÑO PREDICTIVO DEL MODELO

4.1.1 DATOS DEL MODELO PREDICTIVO Y MEDIDOS EN CAMPO

El modelo predictivo de concentraciones del contaminante $PM_{2.5}$ se ejecutó sobre las seis fechas seleccionadas para este análisis con el procedimiento descrito en el capítulo anterior “Metodología para ejecutar el modelo predictivo”. Los valores extraídos para determinar el desempeño del modelo fueron los valores de concentración de $PM_{2.5}$ predichos por el modelo en las coordenadas donde se encuentran las estaciones de la Red Automática de Monitoreo Atmosférico, especificadas en la Tabla 1.7, y, de igual manera, los valores de concentraciones de $PM_{2.5}$ registrados por las mismas estaciones de monitoreo al instante en el que se captura la imagen satelital.

Por motivos fuera del alcance del proyecto, en ocasiones, algunas estaciones de la RAMA no registraron concentraciones de $PM_{2.5}$ en el instante en que se capturaron las escenas que fueron utilizadas para este estudio, razón por la cual las estaciones reportadas no son exactamente las mismas en todas las fechas seleccionadas.

TEMPORADA DE ESTIAJE 2016

En la primera fecha de la temporada de estiaje, el día 21 de enero de 2016, la Red Automática de Monitoreo Atmosférico obtuvo mediciones del contaminante $PM_{2.5}$ en 13 estaciones. En la tabla 4.1 se observa que en la mayoría de las estaciones el modelo sobreestimó las concentraciones de $PM_{2.5}$. Mientras que en nueve casos se tiene una sobreestimación, en un caso, el modelo predijo un valor considerablemente debajo del que se registró para la estación UAM Iztapalapa (UIZ), con un error absoluto de 33.84.

A pesar de observaciones anteriores, podemos percatarnos en la figura 4.1 de que las tendencias de los valores del modelo son congruentes con las de los valores medidos en campo. El error absoluto de todas las predicciones se promedia con un valor de 13.48, el cual se encuentra dentro de los valores aceptables al compararlo con los valores publicados en otras investigaciones.

En la figura 4.2 se observa que las concentraciones de $PM_{2.5}$ son bajas en la zona sur de la ciudad, región cubierta por bosque y suelo dedicado a la agricultura (figura 1.8), el valor de las concentraciones aumenta conforme nos acercamos al norte de la ciudad y nos encontramos con una zona al noroeste con altas concentraciones donde el modelo no tuvo un desempeño tan uniforme como en el resto del mapa.

Tabla 4.1 Resultados para temporada de estiaje 2016 (21 de enero)

Estación	Predicción del modelo	Medición en estación	Error absoluto
AJM	30.78	13	17.78
BJU	37.37	27	10.37
CAM	54.57	38	16.57
CCA	27.28	14	13.28
HGM	33.61	25	8.61
MGH	45.39	36	9.39
MPA	25.22	12	13.22
NEZ	35.39	45	9.61
SAG	46.65	52	5.35
TLA	20.1	33	12.9
UIZ	37.16	71	33.84
UAX	28.34	11	17.34
XAL	45.99	39	6.99
Error Medio Absoluto			13.48




Figura 4.1 Comparación de valores predichos por el modelo contra medidos en campo del 21 de enero de 2016

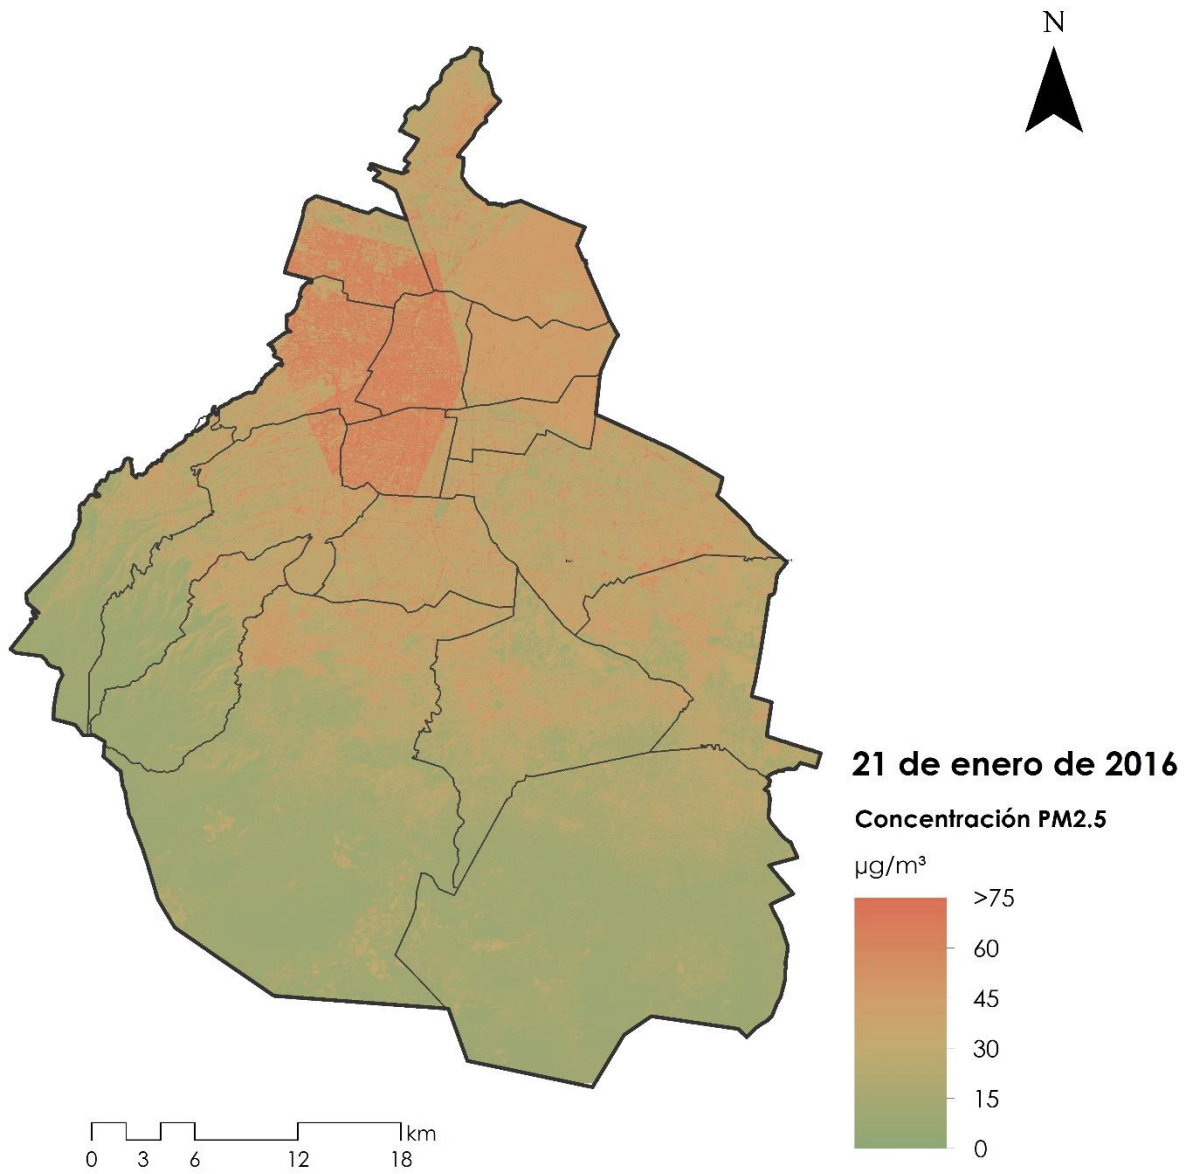


Figura 4.2 Mapa de concentración de PM_{2.5} del 21 de enero de 2016

TEMPORADA DE LLUVIA 2016

En la temporada de lluvias el día 20 de mayo de 2016, se obtuvo un error medio absoluto para 14 registros de 8.46, siendo este el valor más bajo de la serie de fechas presentadas en este trabajo, con la mayoría de los valores arrojados por el modelo predictivo siendo muy cercanos a los medidos en las estaciones de monitoreo, en la figura 4.3 es posible observar con mayor detalle esta tendencia.

La predicción con menor precisión presentó un error medio absoluto de 25.84 para la estación Tlalnepantla (TLA), pero se puede observar que el siguiente error medio de mayor valor es el que se reporta para la estación UAM Xochimilco (UAX) con un valor de 14.91. Por otro lado, en la estación Miguel Hidalgo (MGH) se obtuvo un error medio de 0.07 entre el valor medido y el estimado por el modelo. En 10 registros se tuvo una sobre estimación, mientras que, en 4 casos, el valor medido en estación fue mayor al arrojado por el modelo.

En la figura 4.4 nos encontramos con el mapa de distribución de concentraciones para $PM_{2.5}$ en la primera fecha para temporada de lluvias, en este caso es visualmente evidente como la adición de datos meteorológicos tiene un gran peso en las estimaciones del modelo, es claro en donde se marcan las triangulaciones de Delaunay en el mapa de resultados.

Como en la fecha reportada en la sección anterior la zona sur y oeste de la ciudad reporta valores menores de concentración que el centro norte, respondiendo a la distribución de zonas más pobladas y zonas industriales en el plano de la Ciudad de México. Para esta fecha la zona con peor calidad de aire según nuestro modelo es el oriente y norte de la ciudad.

Tabla 4.2 Resultados para temporada de lluvia 2016 (20 de mayo)

Estación	Predicción del modelo	Medición en estación	Error absoluto
AJU	20.6	17	3.6
AJM	23.79	31	7.21
BJU	31.94	26	5.94
CAM	46.32	46	0.32
CCA	24.24	17	7.24
HGM	21.43	14	7.43
MER	38.52	48	9.48
MGH	22.93	23	0.07
MPA	22.74	14	8.74
NEZ	60.24	47	13.24
TLA	59.84	34	25.84
UIZ	47.28	50	2.72
UAX	29.91	15	14.91
XAL	54.66	43	11.66
Error Medio Absoluto			8.46

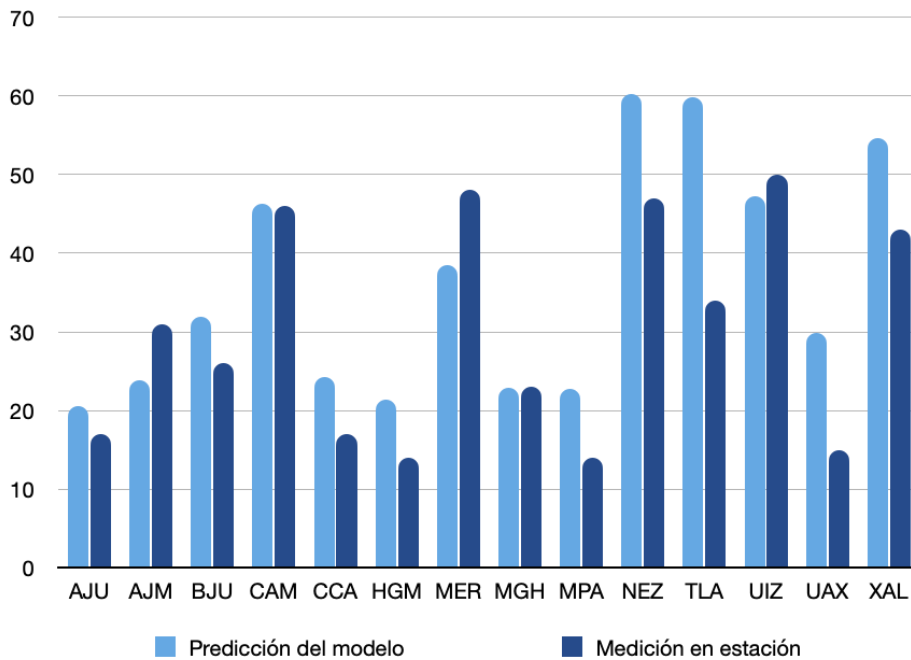


Figura 4.3 Comparación de valores predichos por el modelo contra medidos en campo del 20 de mayo de 2016

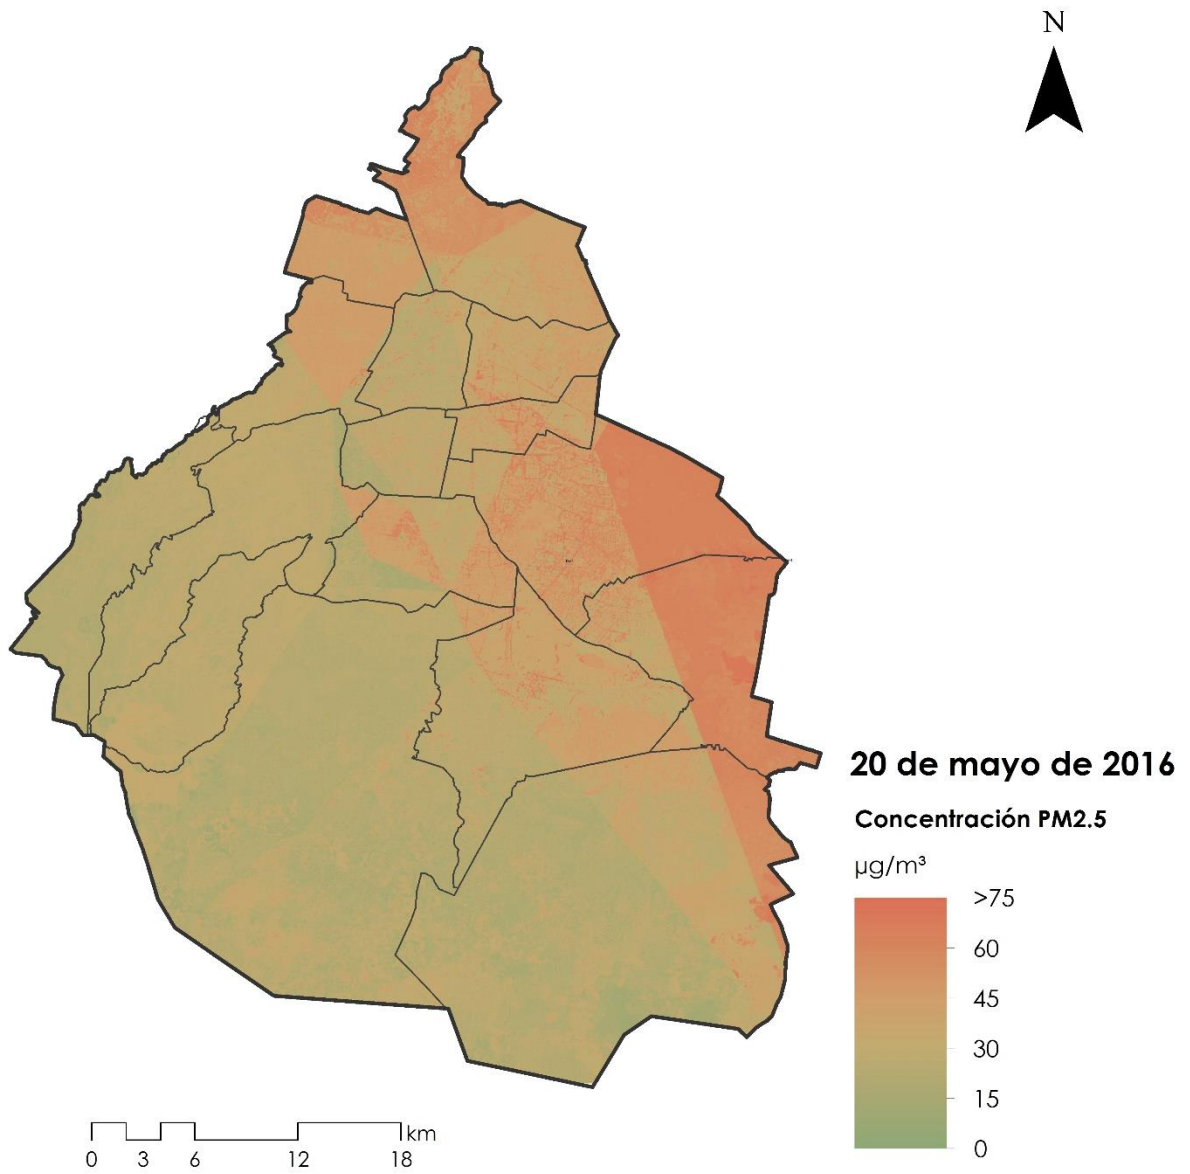


Figura 4.4 Mapa de concentración de PM_{2.5} del 20 de mayo de 2016

TEMPORADA DE ESTIAJE 2018

En la temporada de estiaje del año 2018 el error medio absoluto fue de 26.31, un valor que indica que las predicciones del modelo para 11 estaciones presentaron valores lejanos a los medidos en campo cuando se compara con el error reportado en otras publicaciones. De los 11 valores estimados por el modelo, 4 estuvieron por encima del valor de concentración medida en campo y 7 por debajo.

La mejor estimación de concentración de $PM_{2.5}$ por parte del modelo predictivo fue para la estación Benito Juárez (BJU) con un error absoluto de 3.71, mientras que para la menos precisa en la estación Nezahualcóyotl (NEZ) donde se obtuvo un error absoluto de 71.65. Una observación para esta última estación es que el valor medido en la estación fue de $120 \mu g/m^3$, siendo una concentración sumamente elevada del contaminante atmosférico, lo cual representa un valor fuera de lo común, esto se puede deber a que las mediciones hechas por las estaciones son hechas puntualmente en un espacio y tiempo determinados y estas pueden ser afectadas por fuentes externas en el momento de la medición, como un incendio o algún fenómeno por el estilo, esto provoca un incremento en el error calculado al comparar con el valor estimado por el modelo.

Para esta fecha los valores reportados de concentración de $PM_{2.5}$ son mucho más elevados que en las fechas anteriores, lo cual es esperado ya que las concentraciones de contaminantes atmosféricos suelen ser mayores en temporada de estiaje, y como se aprecia en la figura 4.6 aunque la zona norte reporta concentraciones altas de $PM_{2.5}$, también es posible observar que en el sur de la ciudad los valores reportados no son los menores en esta ocasión, sino que las menores concentraciones se encuentran en el centro-oeste del mapa.

Tabla 4.3 Resultados para temporada de estiaje 2018 (10 de enero)

Estación	Predicción del modelo	Medición en estación	Error absoluto
BJU	42.71	39	3.71
CCA	46.15	32	14.15
GAM	46.12	68	21.88
HGM	24	59	35
MER	42.67	72	29.33
MGH	47.53	42	5.53
NEZ	48.35	120	71.65
SFE	29.91	16	13.91
TLA	51.01	70	18.99
UAX	18.94	45	26.06
XAL	47.81	97	49.19
Error Medio Absoluto			26.31




Figura 4.5 Comparación de valores predichos por el modelo contra medidos en campo del 10 de enero de 2018

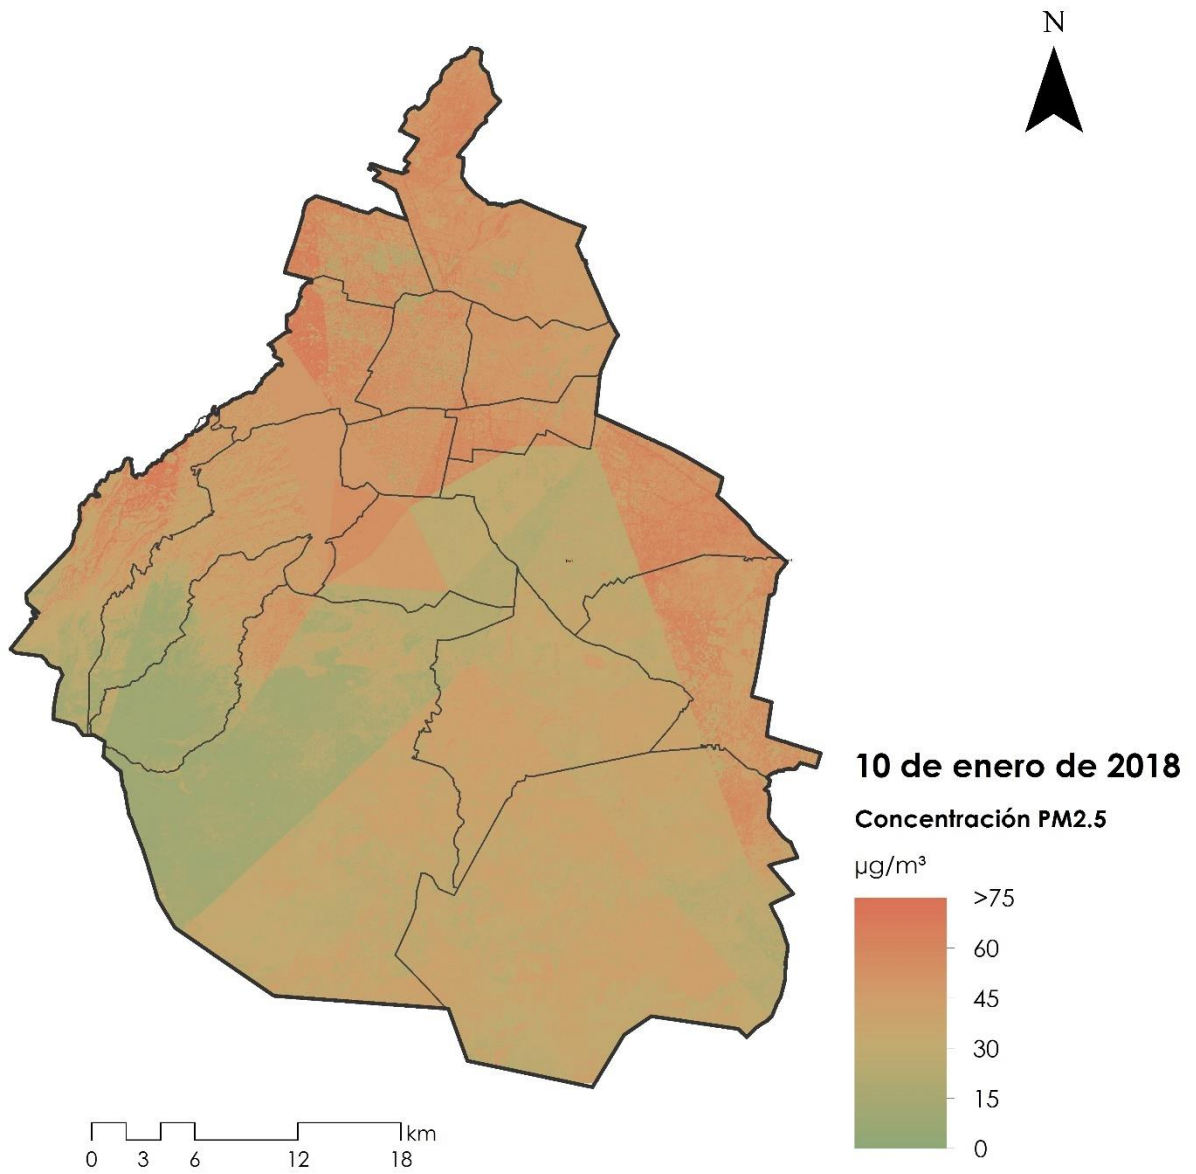


Figura 4.6 Mapa de concentración de PM_{2.5} del 10 de enero de 2018

TEMPORADA DE LLUVIA 2018

La siguiente fecha por analizar fue para la temporada de lluvias 2018 el día 5 de julio. Se calculó el error medio absoluto para 14 registros arrojando un valor de 14.06. A pesar de tener errores absolutos altos como la sobreestimación en la estación Gustavo A. Madero (GAM) por 25.07 $\mu\text{g}/\text{m}^3$ y la subestimación en la estación UNAM Iztapalapa (UIZ) por 26.36 $\mu\text{g}/\text{m}^3$, en esta ocasión el modelo sobreestimó la concentración en once estaciones y la subestimó en solamente tres, sin embargo en la figura 4.7 la gráfica de barras muestra que, en la mayoría de los casos, las tendencias de las estimaciones son congruentes con los valores medidos en campo.

En esta fecha la distribución se nota más uniforme a lo largo de la figura 4.8, reportando valores de medios a altos de concentración de $\text{PM}_{2.5}$. En el poniente de la ciudad se observa una zona sobreestimación del modelo con valores mayores a 75 $\mu\text{g}/\text{m}^3$, según los valores medidos por las estaciones reportados en la tabla 4.4 no existen valores tan altos registrados para esta fecha.

Tabla 4.4 Resultados para temporada de lluvia 2018 (5 de julio)

Estación	Predicción	Medición	Error absoluto
AJM	48.71	24	24.71
BJU	37.39	25	12.39
CCA	15.3	23	7.7
GAM	55.07	30	25.07
HGM	25.73	18	7.73
MER	28.73	25	3.73
MGH	42.18	32	10.18
NEZ	50.9	30	20.9
SAG	42.5	33	9.5
SFE	33.47	40	6.53
TLA	36.8	28	8.8
UIZ	27.64	54	26.36
UAX	36.22	18	18.22
XAL	46.03	31	15.03
Error Medio Absoluto			14.06




Figura 4.7 Comparación de valores predichos por el modelo contra medidos en campo del 10 de enero de 2018

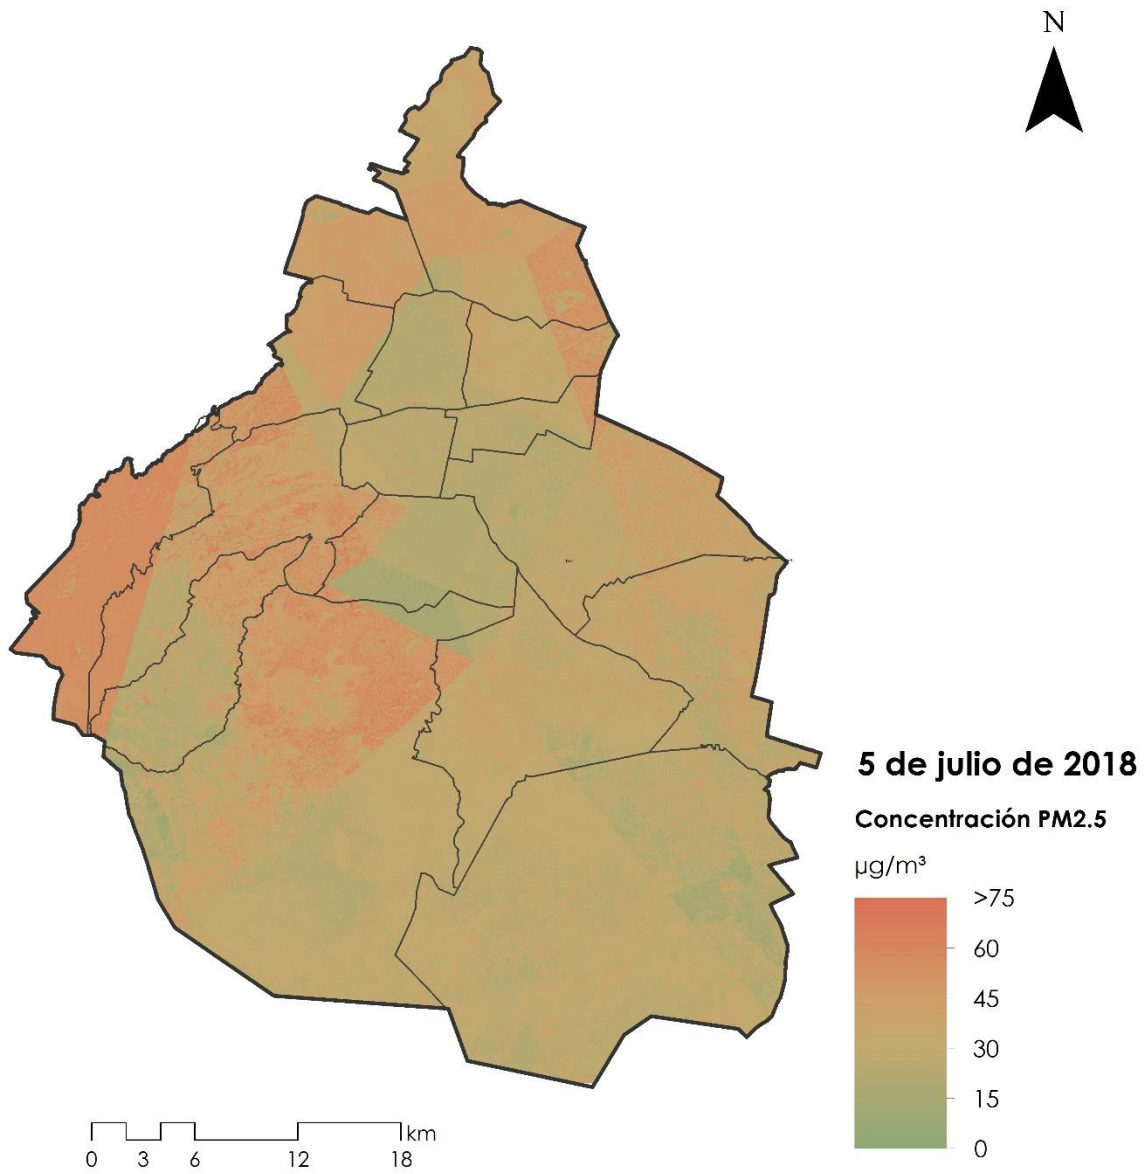


Figura 4.8 Mapa de concentración de PM_{2.5} del 5 de julio de 2018

TEMPORADA DE ESTIAJE 2019

La fecha correspondiente a la temporada de estiaje de 2019 fue el día 29 de enero, en donde se reportaron valores de concentraciones de $PM_{2.5}$ para 12 estaciones. En este caso, el modelo estimó la mitad de los valores por encima de las concentraciones medidas en las estaciones y la mitad por debajo. El error medio absoluto para esta fecha fue de 14.91, resaltando una muy buena estimación para la estación Ajusco (AJU) con un error medio absoluto de $1.71 \mu\text{g}/\text{m}^3$ y un valor muy elevado para la estación Xalostoc (XAL) con una subestimación de $32.21 \mu\text{g}/\text{m}^3$, similar al caso de la estación Hospital General de México (HGM) con $31.11 \mu\text{g}/\text{m}^3$ por parte del modelo predictivo.

A pesar de que respecto al error medio absoluto esta fecha no es la que obtuvo el mejor rendimiento del modelo, visualmente es el más uniforme que se presenta en este trabajo, claramente se observan en la Figura 4.10 las zonas pobladas y el área boscosa que cubre la Ciudad de México, si se analiza con más detalle es posible ver como en las avenidas principales de la ciudad las concentraciones de material particulado son más altas. Este comportamiento del modelo se debe a que no hubo precipitación acumulada en la fecha seleccionada.

Tabla 4.5 Resultados para temporada de estiaje 2019 (29 de enero)

Estación	Predicción del modelo	Medición en estación	Error absoluto
AJM	37.14	16	21.14
AJU	10.71	9	1.71
CCA	22.55	29	6.45
HGM	22.89	54	31.11
NEZ	16.33	41	24.67
PED	34.35	30	4.35
SAG	48.03	46	2.03
SFE	34.94	18	16.94
TLA	56	27	29
UAX	18.39	23	4.61
UIZ	31.29	36	4.71
XAL	24.79	57	32.21
Error Medio Absoluto			14.91

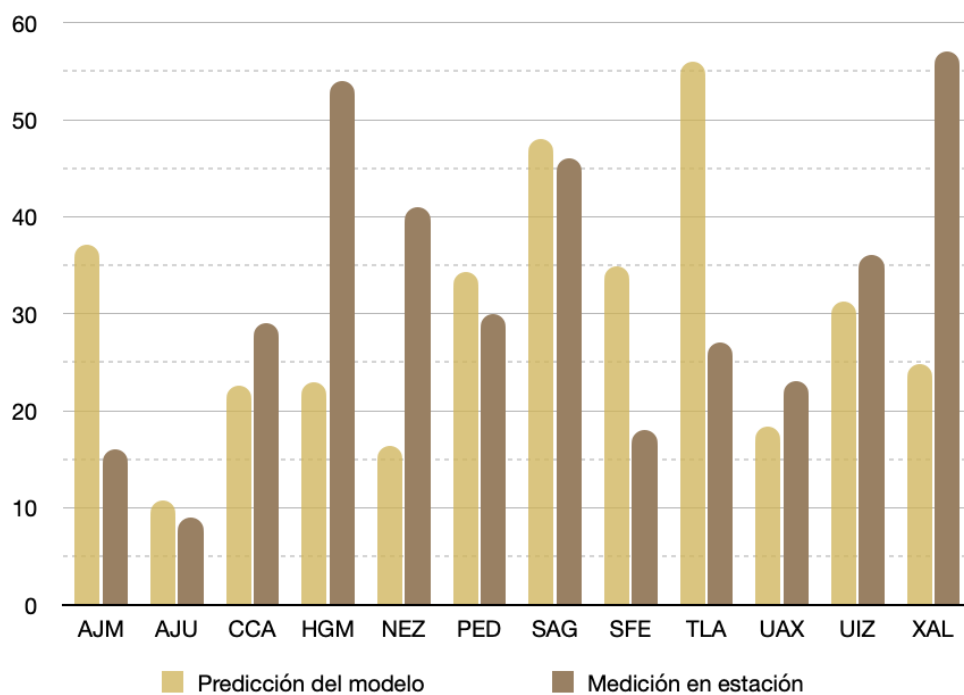


Figura 4.9 Comparación de valores predichos por el modelo contra medidos en campo del 29 de enero de 2019




Figura 4.10 Mapa de concentración de PM_{2.5} del 29 de enero de 2019

TEMPORADA DE LLUVIA 2019

Finalmente, la última fecha seleccionada para temporada de lluvia fue el 8 de julio de 2019, fecha para la cual se tuvieron más registros de estaciones con un total de 16 valores de concentraciones de $PM_{2.5}$ medidos en campo. Una vez más, dominan las sobreestimaciones en doce casos comparado con las cuatro subestimaciones que se reportaron.

Al promediar los errores absolutos de cada estación, el error medio absoluto para esta fecha fue de $16.31 \mu\text{g}/\text{m}^3$, un poco más alto de los valores que se reportan frecuentemente en otras publicaciones. En este conjunto de datos, resalta una sobreestimación en la estación Nezahualcóyotl (NEZ) por $45.34 \mu\text{g}/\text{m}^3$ y una muy buena estimación en la estación Centro de Ciencias de la Atmósfera (CCA) con un error absoluto de $0.48 \mu\text{g}/\text{m}^3$.

Nuevamente al tratarse de una fecha en temporada de lluvia es posible notar las triangulaciones hechas para incorporar datos meteorológicos en el modelo en la figura 4.12, siguiendo la tendencia vista en las imágenes anteriores donde las concentraciones menores se observan en el sur de la ciudad e incrementan en el norte, área con mayor concentración zonas industriales. También se observa una sobreestimación de valores al aplicar el modelo en la zona oriente con valores que rebasan los $75 \mu\text{g}/\text{m}^3$, lo cual no coincide con los valores reportados en la tabla 4.6.

Tabla 4.6 Resultados para temporada de lluvia 2019 (8 de julio)

Estación	Predicción del modelo	Medición en estación	Error absoluto
AJM	29.06	13	16.06
AJU	19.01	23	3.99
BJU	41.8	32	9.8
CCA	21.52	22	0.48
FAR	31.33	10	21.33
GAM	35.46	26	9.46
HGM	41.86	37	4.86
MER	32.67	25	7.67
NEZ	71.34	26	45.34
PED	41.64	25	16.64
SAC	39.01	20	19.01
SAG	49.49	17	32.49
SFE	18.24	24	5.76
TLA	30.65	42	11.35
UAX	44.42	12	32.42
XAL	46.3	22	24.3
Error Medio Absoluto			16.31

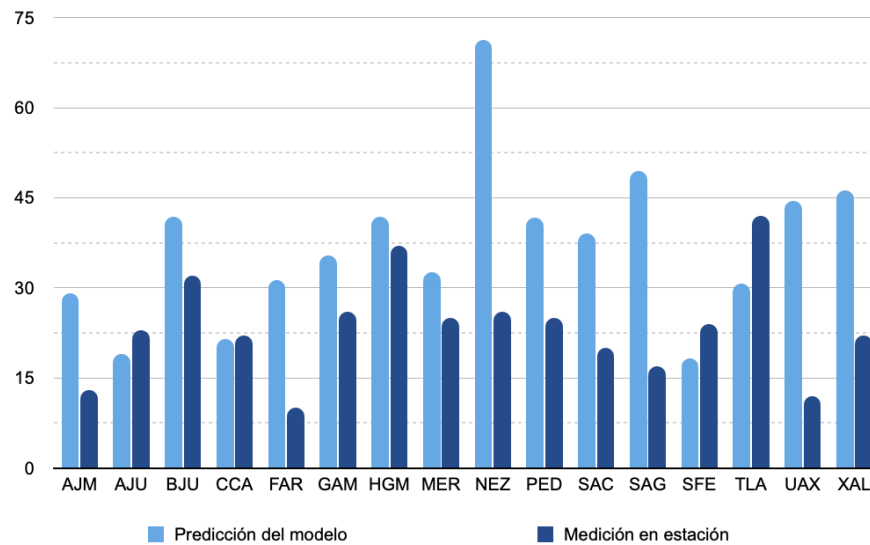


Figura 4.11 Comparación de valores predichos por el modelo contra medidos en campo del 8 de julio de 2019

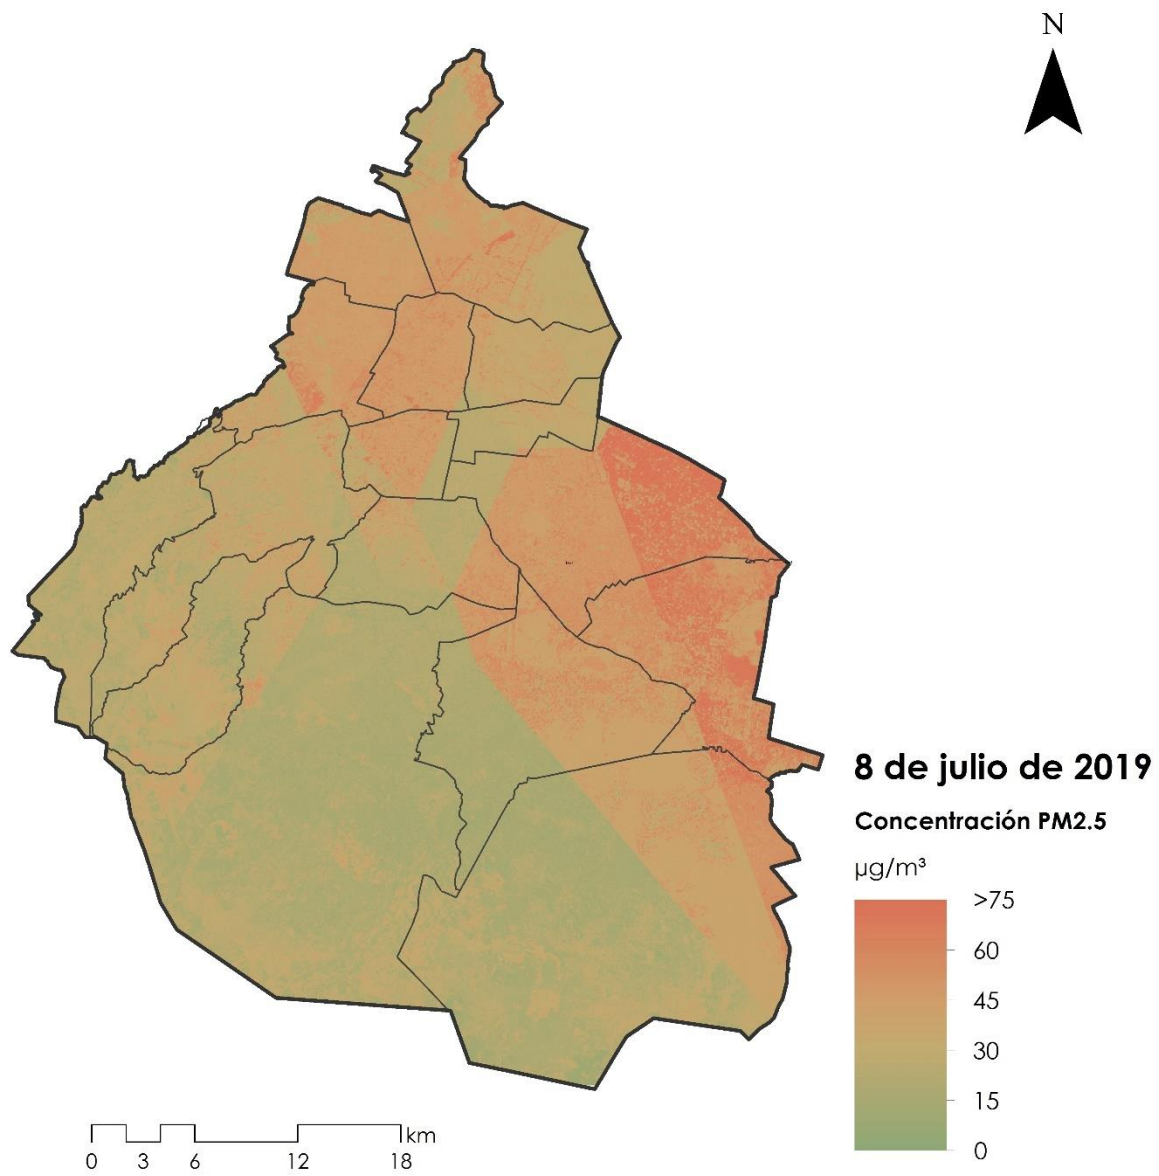


Figura 4.12 Mapa de concentración de PM_{2.5} del 8 de julio de 2019

4.1.2 CRITERIOS DE SELECCIÓN

Con el fin de determinar la veracidad o falsedad de la hipótesis que se plantea en este trabajo, se decidió por calcular el error medio absoluto entre los valores medidos en cada estación de monitoreo y los predichos por el modelo. Para obtener este valor, se determinó el valor absoluto al restar los valores de concentraciones predichos menos los medidos, es decir, el error absoluto por cada estación. La suma de todos los errores absolutos dividida entre el número de estaciones es finalmente el error medio absoluto. Entre más pequeño sea este valor, mejor desempeño tuvo el modelo al momento de predecir las concentraciones de $PM_{2.5}$. Posteriormente se calculó el promedio de los errores medios absolutos tanto en temporada de estiaje como en temporada de lluvias. Se seleccionó adicionalmente la fecha con el menor error medio absoluto como la fecha en la que el modelo mostró el mejor rendimiento.

4.1.3 MAPAS DE CONCENTRACIONES DE $PM_{2.5}$

Se generó un mapa representativo de las concentraciones de $PM_{2.5}$ en áreas de 30 metros por 30 metros para toda la superficie de la CDMX. Para cada mapa, se utilizó una rampa de colores para intervalos de valores en donde el color azul representa los valores más bajos de concentración de $PM_{2.5}$ y el rojo los valores más altos registrados.

4.1.4 EVALUACIÓN MULTITEMPORAL DEL MODELO

Para determinar la temporada en la que el modelo tiene mejor rendimiento, se compararon los resultados del error medio absoluto calculados anteriormente por cada fecha, compilados en la tabla 4.7. Para el año 2016, la temporada de lluvias presentó un EMA 5.02 unidades menor que en la temporada de estiaje. De la misma manera, en 2018 el EMA en la temporada de lluvias fue de 14.06, menor a 26.31 en la temporada de estiaje. Por último, en 2019 se presentó un caso diferente en el que el modelo tuvo mejor rendimiento en la temporada de estiaje con una diferencia de 1.4 unidades.

Tabla 4.7 Rendimiento temporal del modelo

Año	Temporada	Error Medio Absoluto
2016	Estiaje	13.48
	Lluvias	8.46
2018	Estiaje	26.31
	Lluvias	14.06
2019	Estiaje	14.91
	Lluvias	16.31

Finalmente, en la tabla 4.7, se observa que la fecha en la que el modelo tuvo una mejor predicción fue en el 20 mayo de 2016 en la temporada de lluvias. Para esa fecha el EMA fue de 8.46, comparado con el siguiente menor valor calculado en la temporada de estiaje del mismo año, en la temporada de lluvias fue 5.02 unidades menor.

Adicionalmente, se promediaron los errores medio absolutos por temporada y se presentan en la tabla 4.8. Nuevamente se observa que la temporada de lluvias es en la que el modelo tiene un mejor desempeño para estimar las concentraciones del contaminante PM_{2.5} que, en la temporada de estiaje, con una diferencia de 5.29 unidades.

Tabla 4.8 Error medio absoluto por fecha analizada

Temporada	Error Medio Absoluto
Estiaje	18.23333333
Lluvias	12.94333333

5. CONCLUSIONES Y CONTINUIDAD

Se logró retomar el modelo con mejor desempeño de la tesis “Incorporación de datos meteorológicos en la modelación de material particulado $PM_{2.5}$ con redes neuronales en la Ciudad de México” para generar mapas de concentración de $PM_{2.5}$ en la Ciudad de México en los años 2016, 2018 y 2019, tomando una fecha en temporada de lluvias y otra en estiaje para cada año estudiado, además de que se realizó un análisis comparativo de los datos medidos en campo por la Red automática de Monitoreo Atmosférico y los generados con el modelo de redes neuronales.

Al ejecutar el modelo predictivo de $PM_{2.5}$ en la atmósfera de la CDMX para 6 fechas diferentes, se observó que el modelo tuvo un mejor comportamiento en las fechas que corresponden a la temporada de lluvias comparado con la temporada de estiaje. A pesar de que todas las fechas proporcionan al modelo las mismas variables de reflectancias y datos meteorológicos, durante la temporada de lluvias hay valores variables de humedad relativa y precipitación acumulada, a diferencia de la temporada de estiaje donde los valores de humedad relativa son constantes en la temporada de lluvias y la precipitación es prácticamente nula. Finalmente, se puede considerar que la hipótesis planteada para este trabajo fue acertada.

5.1. LIMITACIONES DEL ESTUDIO

Durante el desarrollo de este trabajo se enfrentaron desafíos y obstáculos que limitaron el alcance de los resultados obtenidos por nuestro modelo.

La primera limitación que se identificó fue el tamaño de la base de datos construida para entrenar el modelo que se retomó para este trabajo. Las escenas capturadas por el satélite consideradas incluyen imágenes desde su lanzamiento en febrero de 2013 hasta diciembre de 2018, la resolución temporal es de dieciséis días, en este periodo de tiempo el satélite Landsat 8 pasó por la zona de estudio 126 veces, pero se descartaron las escenas que presentan cobertura de nubes, reduciendo la cantidad de fechas con datos extraíbles

disponibles a 44. Una red neuronal tiene mejor desempeño si la base de datos con la que es entrenada es más robusta, de haber contado con más fechas la fiabilidad del modelo incrementaría.

Por otro lado, la cantidad de estaciones físicas de monitoreo atmosférico y meteorológico distribuidas en la Ciudad de México es reducida, a esto se le suma que la distribución de dichas estaciones no es uniforme, como se observa en la Figura 3.1 la mayoría de estas estaciones están ubicadas en el centro-norte de la zona de estudio. Esta complicación fue principalmente evidente al aplicar la triangulación de Delaunay, ya que los polígonos que representan las zonas de influencia de las estaciones meteorológicas abarcan áreas muy grandes dentro de la ciudad, con lo que se perdió precisión espacial al aplicar el modelo.

5.2. RECOMENDACIONES

Como continuidad de este trabajo, se hacen las siguientes recomendaciones que se podrían implementar en investigaciones posteriores con el fin de la búsqueda de resultados con incluso mayor fiabilidad que la presentada.

Como primera recomendación, se propone la consideración de distintos modelos a utilizar dependiendo de la temporada del año que se requiera analizar, es decir, un modelo predictivo para la temporada de lluvias y uno diferente para la temporada de estiaje. Dado que en este trabajo se demostró que el modelo presentado muestra resultados de mayor precisión durante la temporada de lluvias, se podría trabajar en el desarrollo de un modelo que se desempeñe mejor durante la temporada de estiaje.

Otra sugerencia para futuras investigaciones sería el uso de herramientas de medición controladas por el usuario. Una opción para la recolección de datos de reflectancias sería utilizar drones acondicionados con los sensores requeridos para capturar las reflectancias necesarias. Esto permitiría la adquisición de datos en cualquier momento, sin interferencias de nubes y en zonas específicas, resultando en datos más precisos que los disponibles actualmente. Aunado a esto, el uso de instrumentación portátil para medir datos de

concentraciones de $PM_{2.5}$ y datos meteorológicos permitiría obtener los datos necesarios para lograr la caracterización de la zona de estudio con el detalle que el usuario lo requiera. Por último, se podría hacer uso de los datos capturados por otros satélites con mejor tecnología como el Landsat 9. Utilizando estos datos se podría evitar una inversión mayor por la adquisición de instrumentación costosa.

LISTA DE FIGURAS

Figura 1.1 Comparación de tamaño de partículas de PM _{2.5} (United States Environmental Protection Agency, 2016)	4
Figura 1.2 Espectro electromagnético	8
Figura 1.3 Elementos de un sistema de percepción remota	10
Figura 1.4 Satélite Landsat 8 (NASA, n.d.)	13
Figura 1.5 Arquitectura de una red neuronal artificial	16
Figura 1.6 Ubicación de la zona de estudio.....	18
Figura 1.7 Relieve de la Ciudad de México (Instituto Nacional de Estadística y Geografía, n.d.).....	19
Figura 1.8 Vegetación y agricultura en la Ciudad de México	21
Figura 1.9 Climas en la Ciudad de México según la clasificación de Köppen	22
Figura 1.10 Precipitación acumulada mensual en la Ciudad de México de los años 1985 al 2021 (CONAGUA, 2022).....	23
Figura 1.11 Localización de las estaciones de la Red Automática de Monitoreo Atmosférico en la Ciudad de México	30
Figura 3.1 Estaciones de la RAMA y PEMBU.....	44
Figura 4.1 Comparación de valores predichos por el modelo contra medidos en campo del 21 de enero de 2016.....	49
Figura 4.2 Mapa de concentración de PM _{2.5} del 21 de enero de 2016	50
Figura 4.3 Comparación de valores predichos por el modelo contra medidos en campo del 20 de mayo de 2016	52
Figura 4.4 Mapa de concentración de PM _{2.5} del 20 de mayo de 2016.....	53

Figura 4.5 Comparación de valores predichos por el modelo contra medidos en campo del 10 de enero de 2018.....	55
Figura 4.6 Mapa de concentración de PM _{2.5} del 10 de enero de 2018	56
Figura 4.7 Comparación de valores predichos por el modelo contra medidos en campo del 10 de enero de 2018.....	58
Figura 4.8 Mapa de concentración de PM _{2.5} del 5 de julio de 2018	59
Figura 4.9 Comparación de valores predichos por el modelo contra medidos en campo del 29 de enero de 2019.....	61
Figura 4.10 Mapa de concentración de PM _{2.5} del 29 de enero de 2019	62
Figura 4.11 Comparación de valores predichos por el modelo contra medidos en campo del 8 de julio de 2019.....	64
Figura 4.12 Mapa de concentración de PM _{2.5} del 8 de julio de 2019	65

LISTA DE TABLAS

Tabla 1.1 Principales divisiones del espectro electromagnético (Campbell & Wynne, 2011) .7	7
Tabla 1.2 Bandas captadas por el satélite Landsat 8 (U.S. Geological Survey, 2019)..... 14	14
Tabla 1.3 NOM de salud ambiental vigentes dictadas por la Secretaría de Salud (SSA) (Dirección de Monitoreo Atmosférico de la CDMX, n.d.-c)..... 26	26
Tabla 1.4 NOM técnicas vigentes dictadas por 'la Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT) (Dirección de Monitoreo Atmosférico de la CDMX, n.d.-c)27	27
Tabla 1.5 NOM que regulan la operación de los sistemas de monitoreo de la calidad del aire, su comunicación y requisitos para la elaboración del índice de Calidad en la Ciudad de México (Dirección de Monitoreo Atmosférico de la CDMX, n.d.-c).....28	28
Tabla 1.6 Coordenadas de las estaciones de la Red Automática de Monitoreo Atmosférico en la Ciudad de México (Dirección de Monitoreo Atmosférico de la CDMX, n.d.-b) 31	31
Tabla 3.1 Fechas seleccionadas para el análisis de datos42	42
Tabla 4.1 Resultados para temporada de estiaje 2016 (21 de enero)..... 49	49
Tabla 4.2 Resultados para temporada de lluvia 2016 (20 de mayo).....52	52
Tabla 4.3 Resultados para temporada de estiaje 2018 (10 de enero).....55	55
Tabla 4.4 Resultados para temporada de lluvia 2018 (5 de julio)58	58
Tabla 4.5 Resultados para temporada de estiaje 2019 (29 de enero) 61	61
Tabla 4.6 Resultados para temporada de lluvia 2019 (8 de julio) 64	64
Tabla 4.7 Rendimiento temporal del modelo67	67
Tabla 4.8 Error medio absoluto por fecha analizada67	67

REFERENCIAS

- Aggarwal, C. C. (2018). Neural Networks and Deep Learning. In *Neural Networks and Deep Learning*. <https://doi.org/10.1007/978-3-319-94463-0>
- Amazon Web Services. (2022). *What is a Neural Network? AI and ML Guide - AWS*. <https://aws.amazon.com/what-is/neural-network/>
- Ángeles Salto, P. de J. (2019). *Estimación de la distribución espacio-temporal de concentraciones de material particulado PM_{2.5} con el uso de redes neuronales artificiales e información geoespacial*. Universidad Nacional Autónoma de México.
- Butcher, G., & Mottar, J. (2016). Tour of the Electromagnetic Spectrum. In *National Aeronautics and Space Administration* (Third Edit). National Aeronautics and Space Administration. <http://science.nasa.gov/ems>
- Campbell, J. B., & Wynne, R. H. (2011). *Introduction to Remote Sensing* (Fifth Edit). The Guilford Press.
- Cheng, B., & Titterington, D. M. (1994). Neural networks: A review from a statistical perspective. *Statistical Science*, 9(1). <https://doi.org/10.1214/ss/1177010638>
- Congalton, R. G. (2015). Remote Sensing and Image Interpretation. 7th Edition. In *Photogrammetric Engineering & Remote Sensing* (Vol. 81, Issue 8). <https://doi.org/10.14358/pers.81.8.615>
- Dirección de Monitoreo Atmosférico de la CDMX. (n.d.-a). *El monitoreo de la calidad del aire*. Retrieved November 22, 2022, from <http://www.aire.cdmx.gob.mx/default.php?opc=%27ZaBhnml=%27>
- Dirección de Monitoreo Atmosférico de la CDMX. (n.d.-b). *Estaciones de monitoreo*. Retrieved January 21, 2023, from <http://www.aire.cdmx.gob.mx/default.php?opc=%27ZaBhnml=&dc=%27ZA==>

- Dirección de Monitoreo Atmosférico de la CDMX. (n.d.-c). *Normatividad*. Retrieved November 22, 2022, from <http://www.aire.cdmx.gob.mx/default.php?opc=%27ZaBhnml=%27&dc=Yw==>
- Esworthy, R. (2015). *Air Quality: EPA's 2013 Changes to the Particulate Matter (PM) Standard*. www.crs.gov
- Goddard Media Studios. (2014). *Landsat 8 Onion Skin*. NASA's Goddard Space Flight Center. <https://svs.gsfc.nasa.gov/11491>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/J.RSE.2017.06.031>
- Gupta, P., Christopher, S. A., Wang, J., Gehrig, R., Lee, Y., & Kumar, N. (2006). Satellite remote sensing of particulate matter and air quality assessment over global cities. *Atmospheric Environment*, 40(30), 5880–5892. <https://doi.org/10.1016/j.atmosenv.2006.03.016>
- Haber, S. H., Elena, L., Varela, P., Mexicana, S. H., Una, H., Li, C., & Mar, J. (1993). La Industrialización De Mexico : Historiografía Y Análisis. *HMex*, XLII(3).
- Hamzelo, M., Gharagozlou, A., Sadeghian, S., Baikpour, S. H., & Rajabi, A. (2015). Modelling of carbon monoxide air pollution in large cities by evaluation of spectral LANDSAT8 images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 40(1W5), 281–285. <https://doi.org/10.5194/isprsarchives-XL-1-W5-281-2015>
- Haykin, S. (1999). Neural networks: a comprehensive foundation by Simon Haykin. In *The Knowledge Engineering Review* (Vol. 13, Issue 4).
- Health Organization, W., & Office for Europe, R. (2013). *Health effects of particulate matter*.

- IBM, C. E. (2020). *What are Neural Networks?* IBM. <https://www.ibm.com/cloud/learn/neural-networks>
- INEGI. (2021). *EN LA CIUDAD DE MÉXICO SOMOS 9 209 944 HABITANTES: CENSO DE POBLACIÓN Y VIVIENDA 2020*. https://www.inegi.org.mx/contenidos/saladeprensa/boletines/2021/EstSociodemo/ResultCenso2020_CdMx.pdf
- Instituto de Ciencias de la Atmósfera y Cambio Climático. (2021). *Historia*. <https://www.atmosfera.unam.mx/historia/>
- Instituto Nacional de Estadística y Geografía. (n.d.). *Biblioteca digital de Mapas*. Retrieved April 9, 2023, from <https://www.inegi.org.mx/app/mapas/>
- Jáuregui Ostos, E. (2000). El clima de la Ciudad de México. *Instituto de Geografía*.
- Kamarul Zaman, N. A. F., Kanniah, K. D., & Kaskaoutis, D. G. (2017). Estimating Particulate Matter using satellite based aerosol optical depth and meteorological variables in Malaysia. *Atmospheric Research*, 193(October 2016), 142–162. <https://doi.org/10.1016/j.atmosres.2017.04.019>
- Kim, K. H., Kabir, E., & Kabir, S. (2015). A review on the human health impact of airborne particulate matter. *Environment International*, 74, 136–143. <https://doi.org/10.1016/j.envint.2014.10.005>
- Lyu, H., Dai, T., Zheng, Y., Shi, G., & Nakajima, T. (2018). Estimation of PM_{2.5} concentrations over Beijing with MODIS AODs using an artificial neural network. *Scientific Online Letters on the Atmosphere*, 14, 14–18. <https://doi.org/10.2151/sola.2018-003>
- Marr, L. C., Grogan, L. A., Wohrnschimmel, H., Molina, L. T., Molina, M. J., Smith, T. J., & Garshick, E. (2004). Vehicle Traffic as a Source of Particulate Polycyclic Aromatic Hydrocarbon Exposure in the Mexico City Metropolitan Area. *Environmental Science and Technology*, 38(9). <https://doi.org/10.1021/es034962s>

- McLean, D. (2000). Kevin Gurney, *An Introduction to Neural Networks*, University College London (UCL) Press, 1997. ISBN 1-85728-673-1 HB. £14.95. xi+234 pages. *Natural Language Engineering*, 6(2), 203–204. <https://doi.org/10.1017/S1351324900002540>
- Miller, L., & Xu, X. (2018). Ambient PM_{2.5} Human Health Effects—Findings in China and Research Directions. *Atmosphere*, 9(11), 424. <https://doi.org/10.3390/atmos9110424>
- Molina, L. T., de Foy, B., Vázquez Martínez, O., Hugo, V., & Figueroa, P. (2009). Air quality, weather and climate in Mexico City. *WMO Bulletin*, 8(581).
- Molina, M. J., & Molina, L. T. (2004). Megacities and Atmospheric Pollution. *Journal of the Air & Waste Management Association*, 54(6), 644–680. <https://doi.org/10.1080/10473289.2004.10470936>
- NASA. (n.d.). *Landsat 8*. Retrieved January 21, 2023, from <https://landsat.gsfc.nasa.gov/satellites/landsat-8/>
- National Aeronautics and Space Administration Goddard Space Flight Center. (2013). *The Electromagnetic Spectrum*. <https://imagine.gsfc.nasa.gov/science/toolbox/emspectrum1.html>
- National Aeronautics and Space Administration. (2021). *What is Remote Sensing?* Earth Data. <https://earthdata.nasa.gov/learn/remote-sensing>
- Othman, N., Jafri, M. Z. M., & San, L. H. (2010). Estimating particulate matter concentration over arid region using satellite remote sensing: A case study in Makkah, Saudi Arabia. *Modern Applied Science*, 4(11), 131. <https://doi.org/10.5539/mas.v4n11p131>
- PAOT. (2014). *Áreas Verdes Urbanas del Distrito Federal*. http://centro.paot.org.mx/documentos/paot/estudios/Areas_Verdes.pdf
- PEMBU. (2022). *Programa de Estaciones Meteorológicas del Bachillerato Universitario*. <https://www.ruoa.unam.mx/pembu/index.php?page=mision>
- Prud'homme, G., Dobbin, N. A., Sun, L., Burnett, R. T., Martin, R. V., Davidson, A., Cakmak, S., Villeneuve, P. J., Lamsal, L. N., van Donkelaar, A., Peters, P. A., & Johnson, M. (2013).

- Comparison of remote sensing and fixed-site monitoring approaches for examining air pollution and health in a national study population. *Atmospheric Environment*, 80, 161–171. <https://doi.org/10.1016/j.atmosenv.2013.07.020>
- Ramírez Casas, F. A. (2020). *Incorporación de datos meteorológicos en la modelación de material particulado PM_{2.5} con redes neuronales en la Ciudad de México* [Universidad Nacional Autónoma de México]. <http://132.248.9.195/ptd2020/octubre/o8o4689/Index.html>
- Read, J. M., & Torrado, M. (2009). Remote Sensing. *International Encyclopedia of Human Geography*, 335–346. <https://doi.org/10.1016/B978-008044910-4.00508-3>
- Roy, D. P., Wulder, M. A., Loveland, T. R., C.E., W., Allen, R. G., Anderson, M. C., Helder, D., Irons, J. R., Johnson, D. M., Kennedy, R., Scambos, T. A., Schaaf, C. B., Schott, J. R., Sheng, Y., Vermote, E. F., Belward, A. S., Bindschadler, R., Cohen, W. B., Gao, F., ... Zhu, Z. (2014). Landsat-8: Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 145, 154–172. <https://doi.org/10.1016/j.rse.2014.02.001>
- Saraswat, I., Mishra, R. K., & Kumar, A. (2017). Estimation of PM₁₀ concentration from Landsat 8 OLI satellite imagery over Delhi, India. *Remote Sensing Applications: Society and Environment*, 8(April), 251–257. <https://doi.org/10.1016/j.rsase.2017.10.006>
- Schalkoff, R. J. (1997). *Artificial neural networks*. 422. https://books.google.com/books/about/Artificial_Neural_Networks.html?id=8JFNPgAACAAJ
- Secretaría de Salud. (2021). *NORMA OFICIAL MEXICANA NOM-025-SSA1-2021, SALUD AMBIENTAL. CRITERIO PARA EVALUAR LA CALIDAD DEL AIRE AMBIENTE, CON RESPECTO A LAS PARTÍCULAS SUSPENDIDAS PM₁₀ Y PM_{2.5}. VALORES NORMADOS PARA LA CONCENTRACIÓN DE PARTÍCULAS SUSPENDIDAS PM₁₀ Y PM_{2.5} EN EL AIRE AMBIENTE, COMO MEDIDA DE PROTECCIÓN A LA SALUD DE LA POBLACIÓN*. Diario Oficial de la Federación.

- Servicio Meteorológico Nacional. (2021). *Funciones y Objetivos*.
<https://smn.conagua.gob.mx/es/smn/funciones-y-objetivos>
- United States Environmental Protection Agency. (2016). *Particulate Matter (PM) Basics*.
<https://www.epa.gov/pm-pollution/particulate-matter-pm-basics#PM>
- U.S. Geological Survey. (2019). *Landsat 8 (L8) Data Users Handbook*.
- U.S. Geological Survey. (2021). *Landsat Satellite Missions*. U.S. Geological Survey.
<https://www.usgs.gov/core-science-systems/nli/landsat/landsat-satellite-missions>
- Villar-Vidal, M., Lertxundi, A., Martínez López de Dicastillo, M. D., Alvarez, J. I., Santa Marina, L., Ayerdi, M., Basterrechea, M., & Ibarluzea, J. (2014). Air polycyclic aromatic hydrocarbons (PAHs) associated with PM_{2.5} in a north cantabric coast urban environment. *Chemosphere*, 99. <https://doi.org/10.1016/j.chemosphere.2013.11.006>
- Wheeler, A. J., Xu, X., Kulka, R., You, H., Wallace, L., Mallach, G., van Ryswyk, K., MacNeill, M., Kearney, J., Rasmussen, P. E., Dabek-Zlotorzynska, E., Wang, D., Poon, R., Williams, R., Stocco, C., Anastassopoulos, A., Miller, J. D., Dales, R., & Brook, J. R. (2011). Windsor, Ontario exposure assessment study: Design and methods validation of personal, indoor, and outdoor air pollution monitoring. *Journal of the Air and Waste Management Association*, 61(2). <https://doi.org/10.3155/1047-3289.61.2.142>
- Wright, J., Lillesand, T. M., & Kiefer, R. W. (2015). Remote Sensing and Image Interpretation, 7th Edition. In *The Geographical Journal* (Issue 3). John Wiley & Sons.
<https://www.jstor.org/stable/634969?origin=crossref>
- Zhang, X., Chu, Y., Wang, Y., & Zhang, K. (2018). Predicting daily PM_{2.5} concentrations in Texas using high-resolution satellite aerosol optical depth. *Science of the Total Environment*, 631–632, 904–911. <https://doi.org/10.1016/j.scitotenv.2018.02.255>