

Aplicaciones geoestadísticas para la evaluación de la contaminación por ozono en la ciudad de Durango, México

Geostatistical applications for ozone pollution assessment in Durango city, México

José Manuel Loera-Sánchez ¹

Hugo Ramírez-Aldaba ¹  [0000-0002-0370-3794](https://orcid.org/0000-0002-0370-3794)

Arnulfo Meléndez Soto ¹  [0000-0002-4536-7186](https://orcid.org/0000-0002-4536-7186)

Emily García-Montiel ¹  [0000-0002-8814-5655](https://orcid.org/0000-0002-8814-5655)

Rubén González-Laredo ^{1, 2}  [0000-0001-6329-1413](https://orcid.org/0000-0001-6329-1413)

¹ Universidad Juárez del Estado de Durango ✉ h_ramirez@ujed.mx

² Tecnológico Nacional de México – Instituto Tecnológico de Durango

© Universidad De La Salle Bajío (México)

Palabras clave: contaminación atmosférica; geomática; geoestadística; interpolación espacial; *Kriging*; ozono; temperatura; compuestos orgánicos volátiles; precursores de ozono; distribución espacial; química atmosférica

Keywords: atmospheric pollution; geomatic; geostatistics; spatial interpolation; *Kriging*; ozone; temperature; volatile organic compounds; ozone precursors; spatial distribution; atmospheric chemistry

Recepción: 22 – 01 – 2021 / Aceptación: 01 – 06 – 2021

Resumen

Introducción: la contaminación del aire es un problema ambiental causado por actividades antropogénicas. Uno de los contaminantes con mayor impacto a la salud es el ozono, derivado de los óxidos de nitrógeno (NOx) y compuestos orgánicos volátiles que reaccionan con la radiación solar para formar el ozono troposférico. Estos procesos de oxidación en la química atmosférica se conocen como precursores biogénicos del ozono (Compuestos Orgánicos Volátiles Biogénicos, COVB) afectando al balance global del carbono donde los incendios forestales se consideran emisores de dióxido de carbono y NOx (Radke *et al.*, 1991). Los tejidos de las plantas contienen compuestos orgánicos que, emitidos en cantidades suficientes, pueden influir en la química atmosférica (Main, 2003). Una de las herramientas geoespaciales de la geomática que permite modelar y analizar la distribución de contaminantes en el aire es la aplicación de la geoestadística mediante la interpolación. El objeto de este análisis es representar los patrones espaciales de las concentraciones de O₃ por medio de la estimación de valores en áreas no muestreadas.

Método: La interpolación espacial destaca como técnica para la evaluación de la contaminación atmosférica, que posibilita la identificación de zonas expuestas a niveles de riesgo de algún

contaminante. Análisis de regresión e interpolación como *Kriging*, permiten la predicción de ozono en zonas no muestreadas de la Ciudad de Durango. También permite identificar estratos de población en zona urbana y puntos críticos de contaminación, además es posible evaluar el grado de exposición a niveles de ozono.

Resultados: el promedio horario por mes calculado en las tres estaciones permitió determinar el lapso en que la concentración de O₃ fue máxima y mínima. Con las interpolaciones realizadas con método *Kriging* ordinario, y mediante álgebra de mapas, se determinó la zona de influencia del contaminante. Existen mayores concentraciones en la zona poniente de la ciudad; esto coincide con otros estudios que muestran que los niveles de O₃ fueron mayores en las periferias que en la zona centro debido a la vegetación, que aporta precursores del O₃. La zona de influencia se encuentra distribuida en áreas donde se rebasa el valor promedio de 0.032 ppm de dos hasta 11 veces en 24 horas.

Conclusión: el análisis del ciclo diurno del ozono mostró mayores concentraciones en mayo. El método *Kriging* ordinario realizó una predicción aceptable, de acuerdo con los errores de predicción presentados en otros trabajos, considerando el número de estaciones para determinar la zona de influencia, donde se rebasó el promedio de concentración de ozono troposférico. El ozono mostró correlación positiva con la variable de *temperatura* en la zona central y noroeste, mientras que presentó una positiva y menor en la zona poniente. Esta relación indica que los niveles de O₃ en la ciudad dependen significativamente de la temperatura.

Abstract

Introduction: air pollution is an environmental problem caused by anthropogenic activities. One of the pollutants with the greatest impact on health is ozone, derived from nitrogen oxides (NO_x) and volatile organic compounds that react with solar radiation to form tropospheric ozone. These oxidation processes in atmospheric chemistry are known as biogenic ozone precursors (biogenic Volatile Organic Compounds, VOCs) affecting the global carbon balance where forest fires are considered emitters of carbon dioxide and NO_x (Radke *et al.* 1991). Plant tissues contain organic compounds that emitted in sufficient quantities can influence atmospheric chemistry (Main, 2003). One of the geospatial tools of geomatics that allows modeling and analysis of the distribution of pollutants in the air is the application of geostatistics through interpolation. The purpose of this analysis is to represent the spatial patterns of O₃ concentrations by estimating values in non-sampled areas.

Methods: spatial interpolation stands out as a technique for the evaluation of atmospheric pollution, which makes it possible to identify areas exposed to risk levels of some pollutant. Regression and interpolation analysis, such as Kriging, allow the prediction of ozone in non-sampled areas of the city of Durango. It also allows the identification of population strata in urban areas and pollution hotspots, and it is also possible to evaluate the degree of exposure to ozone levels.

Results: the hourly average per month calculated at the three stations allowed determine the period in which the O₃ concentration was at its maximum and minimum. With the interpolations performed with the ordinary Kriging method and by means of map algebra, the zone of influence of the pollutant was determined. There are higher concentrations in the western part of the city; this coincides with other studies where O₃ levels were higher in the outskirts than in the central area, due to the vegetation, which provides O₃ precursors. The zone of influence is distributed in areas where the average value of 0.032 ppm is exceeded from two to 11 times in 24 hours.

Conclusion: The analysis of the diurnal ozone cycle showed higher concentrations in May. The ordinary Kriging method performed an acceptable prediction according to the prediction errors presented in other research, considering the number of stations to determine the zone of influence where the average tropospheric ozone concentration was exceeded. Ozone showed a positive correlation with the temperature variable in the central and northwest zone, while it presented a positive and lower correlation in the west zone. This relationship indicates that O₃ levels in the city depend significantly on temperature.

Introducción

Derivado de las actividades antropogénicas, en la Ciudad de Durango se han originado diversos problemas ambientales. Uno de los más conocidos es la contaminación del aire, la cual se explica como la introducción de agentes que modifican la composición normal o equilibrada de la atmósfera (OMS, 2018). Estos agentes son producto principalmente de actividades como la utilización de medios de transporte y la actividad industrial (Bradley, 2007). Los contaminantes de mayor impacto a la salud son el material particulado, compuestos orgánicos volátiles, contaminantes gaseosos como el ozono (O₃), monóxido de carbono, óxidos de nitrógeno y óxidos de azufre (Rodríguez-Fernández *et al.*, 2019).

El ozono troposférico o de bajo nivel es formado fotoquímicamente, lo que indica una fuerte relación con variables meteorológicas, como la radiación solar (Cano *et al.*, 2016). Es un contaminante secundario en la atmósfera, donde los contaminantes primarios como los óxidos de nitrógeno y los compuestos orgánicos volátiles reaccionan con la radiación solar dando lugar a la formación de O₃ (Malley *et al.*, 2017). Guenther (2000) considera precursores biogénicos (COVB's) para el ozono las erupciones volcánicas formadas por dióxido de azufre, dióxido de carbono, ácido sulfhídrico, etano, propano entre otros que, combinadas con la lluvia y relámpagos, generan descargas eléctricas de gran voltaje y logran la disociación del nitrógeno molecular, formando óxidos de nitrógeno que son precursores atmosféricos importantes del ozono troposférico. De igual consideración son los incendios forestales provocados por relámpagos de forma natural, la radiación intensa, las prácticas agrícolas adversas al bosque y los incendios provocados, en cada caso se quema biomasa, la cual tiene emisiones de dióxido de carbono, óxidos de nitrógeno, algunos alcanos y alquenos (Cheng *et al.*, 1998). Consecuentemente se tendrán altas concentraciones de ozono en áreas rurales en época de estiaje. El ciclo natural del nitrógeno es considerado otro precursor pues interviene en la dinámica microbiana con los procesos de nitrificación y des nitrificación. Donde mediante procesos bióticos ya bióticos emitiendo óxido nítrico y óxido nitroso a la atmosfera. Los tejidos de las plantas al contener una variedad de compuestos orgánicos, sintetizados por la planta y contenidos en ella, logran influir en la química atmosférica, ya que contienen desde alcoholes, cetonas, alcanos, aldehídos, terpenos entre otros y con las variaciones diurnas de temperatura y radiación solar, son emitidos en cantidades suficientes para realizar una contribución significativa en estos precursores de ozono (Guenther *et al.*, 2000). Las concentraciones de O₃, se han asociado significativamente con el impacto a la salud (Xie, 2019), así como con las consultas a urgencias por afecciones respiratorias, principalmente en niños de cinco años o menores (Hernández-Cadena *et al.*, 2007). El ozono también puede ser un potenciador de daños cognitivos particularmente en la adultez (Bello-Medina *et al.*, 2019). Las reacciones fotoquímicas juegan un papel importante en la generación del ozono troposférico. En temporadas secas, con temperaturas más cálidas, las concentraciones de ozono son más altas, mientras que, en temporadas de frío y lluvia, son menores (Son *et al.*, 2018; Gunthe *et al.*, 2016 y Bravo, 2000). Con las herramientas de Geomática, es posible modelar y analizar mediante técnicas geoestadísticas la distribución de contaminantes en el aire (Basagaña, 2012; Zhao, 2018 y Janssen, 2008). Es decir, se pueden aplicar estas herramientas con fines ambientales y de análisis para

desarrollar estrategias de prevención o mitigación de daños ambientales derivados de la polución del aire (López-Rodríguez *et al.*, 2009). Por ejemplo, al modelar la distribución de la contaminación por O₃ en un área experimental (Lee, 2003), se ha encontrado una mayor concentración en las áreas donde se genera tráfico vehicular, esto en ciudades no industriales (Hoek, 2008). La modelación de la calidad del aire es ampliamente aplicada para producir mapas de concentración a escala urbana y evaluar la exposición de la población a la contaminación (Beauchamp *et al.*, 2018). En ese mismo contexto la geoestadística representa una clase de técnicas desarrolladas para analizar y predecir valores espaciales de alguna propiedad (Shukla *et al.*, 2019). Destaca, por ejemplo, la técnica de interpolación espacial *Kriging*, mediante la cual se pueden predecir valores de la variable de interés en zonas no muestreadas (Joseph *et al.*, 2013 y Emery, 2013). Estudios en ciudades como Maracaibo, Barcelona, Madrid, Beijing, Houston, Badajoz, así como en Corea del Sur, han demostrado la utilidad de este método geoestadístico para la evaluación de la contaminación del aire (Cano *et al.*, 2016; Cañada *et al.*, 2015; López-Rodríguez *et al.*, 2009; Michael *et al.*, 2018; Xie *et al.*, 2019 y Jung *et al.*, 2016). La identificación de zonas expuestas a niveles peligrosos de algún contaminante posibilitaría correlacionar la zona de estudio, con otros factores de probable influencia como lo es la exposición de la población a la contaminación, la evaluación de los riesgos asociados, la determinación de impactos y la explicación de las posibles consecuencias (Cañada *et al.*, 2014). Al respecto, en la Ciudad de Durango existen tres estaciones de monitoreo de la calidad del aire, localizadas de oriente a poniente. Sin embargo, las estaciones no presentan una cobertura completa de las actividades en la mancha urbana por las características propias de las estaciones, la ubicación y el número de estas. Por consiguiente, los análisis basados en las estaciones del Sistema de Monitoreo de Calidad del aire, resultan con una representatividad limitada. El ozono es conocido como un irritante respiratorio (Tian *et al.*, 2020) y su influencia como contaminante se manifiesta al penetrar en las vías respiratorias causando diversos daños o efectos a la salud (López, 2009). Por tanto, el objetivo de este análisis es representar los patrones espaciales de las concentraciones de O₃ por medio de la estimación de valores en áreas no muestreadas de la ciudad en el mes de mayo del año 2019.

Método

La Ciudad de Durango es la capital del Estado de Durango y se localiza entre las coordenadas 24° 4' 43.34'', -104° 34' 57.03'', 23° 58' 53.83'', -104° 36' 30.22'', con una altitud de 1 890 m. En la

fig. 1 se visualizan las tres estaciones de monitoreo de la calidad del aire de la Secretaría de Recursos Naturales y Medio Ambiente y su zona de representatividad en la zona urbana de la ciudad de Durango, Dgo.

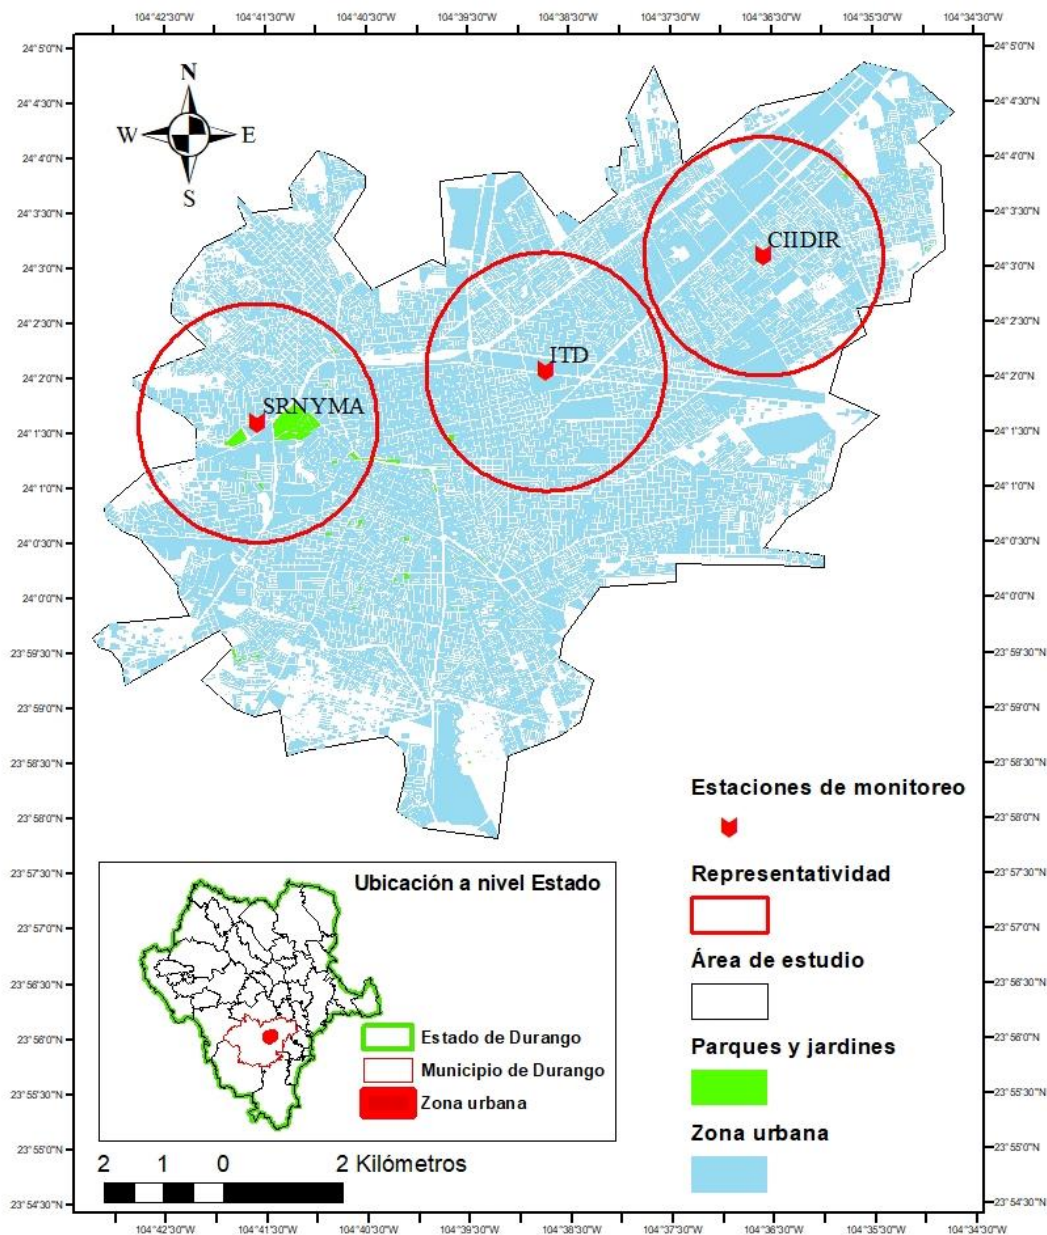


Fig. 1. Mapa de localización y área de estudio.

Fuente: SRNYMA: Secretaría de Recursos Naturales y Medio Ambiente. ITD: TecNM/Instituto Tecnológico de Durango. CIIDIR: Centro Interdisciplinario de Investigación para el Desarrollo Integral Regional del Instituto Politécnico Nacional.

Fig. 1. Localization map and study area.

Source: SRNYMA: Secretariat of Natural Resources and environment. ITD: TecNM/Technological Institute of Durango. CIIDIR: Interdisciplinary Research Center for Integral Regional Development of the National Polytechnic Institute.

La principal base de datos con la que se cuenta para este estudio, es proporcionada por la Secretaría de Recursos Naturales y Medio Ambiente (SRNYMA) a la Facultad de Ciencias Forestales de la Universidad Juárez del Estado de Durango. Esto ha permitido utilizar los datos de muestreo realizados en las tres estaciones de monitoreo de la calidad del aire existentes en la Ciudad de Durango para fines de investigación. La base de datos de la SRNYMA contiene mediciones por hora desde el año 2014 hasta el 2019.

La información utilizada respecto a la población corresponde al censo realizado en 2010 por el Instituto Nacional de Estadística y Geografía (INEGI) donde se incluye información sobre bienes y calidad de vida, además de características de la población como la edad y sexo. Los métodos de interpolación geoestadística forman parte del análisis espacial de los softwares de sistemas de información geográfica, además de los lenguajes de programación “Python *software* Foundation” y el *software* “Team R. Core.”, que permiten realizar análisis estadísticos de variables de interés.

Para el análisis de la base de datos de la SRNYMA, se estructuraron los datos tabulares en Excel, previamente validados y capturados por los criterios mencionados en la Norma Oficial Mexicana (Nom-156-SEMARNAT-2012), mostrando solo periodos de tiempo comunes en las tres estaciones de monitoreo conteniendo datos respecto a las concentraciones de ozono. El método de referencia para determinar la concentración de ozono en el aire ambiente, es el de luminiscencia química (Nom-036-SEMARNAT-1993) (DOF, 2012). El O₃ tiene la capacidad de emitir luz al reaccionar con etileno. En este método se hace entrar simultáneamente aire y etileno a la cámara de mezclado del analizador de O₃. Ahí, el O₃ presente en el aire reacciona con el etileno emitiendo una luz, que se detecta a través de un tubo fotomultiplicador. La fotocorriente resultante se amplifica y puede leerse directamente o mostrarse en un registrador, de acuerdo con la cinética de la reacción que se describe en el Diario Oficial de la Federación (DOF, 2003). El sistema electrónico de detección y procesamiento de la señal reciben, amplifican y procesan la señal resultante de la reacción, para convertirla en señal analógica que permita registrar mediante dispositivos especiales las lecturas del contaminante. En cuestión al ozono, el Sistema Nacional de Monitoreo Atmosférico cuenta con equipos de marca *Thermo Scientific Model 49i*, aprobado por la EPA (Environmental Protection Agency). Este equipo arroja la concentración en partículas por billón (ppb). Las estaciones registran la concentración de O₃ en cada hora del día, todos los días del año, desde el año 2014 hasta la fecha. El año 2019 se consideró como el más completo para el

estudio debido a la mayor cantidad de mediciones con respecto a los años anteriores. Se identificó el mes con mayor concentración del O₃ troposférico, se calcularon los promedios horarios obteniendo 24 valores, correspondientes a las 24 horas del día.

Debido a la influencia que tiene la meteorología en la formación de este contaminante, las variables de importancia en este estudio fueron la temperatura y el O₃. Los promedios horarios se relacionaron con la temperatura horaria. Se modeló la relación entre la temperatura y la concentración de O₃ en el mes de mayo, tomando en cuenta que el periodo de mayor radiación solar en la ciudad es de abril a junio (Weather Spark, 2019).

La base de datos de salud fue proporcionada por la Secretaría de Salud del estado de Durango, donde se obtuvieron los registros de las admisiones por infecciones respiratorias agudas en 30 centros médicos de la ciudad de Durango. Se realizaron histogramas de frecuencias para analizar el comportamiento anual de estas enfermedades e identificar los rangos de edades más propensos a presentar infecciones respiratorias. Para la georreferenciación de datos censales de INEGI en la zona urbana se generó una base de datos geoespacial para identificar la densidad de población y relacionarla con la exposición a la contaminación.

Los métodos de interpolación espacial son algunas de las herramientas de análisis geoestadístico del software de Sistemas de Información Geográfica (SIG) que permiten realizar análisis de predicción espacial, por ejemplo, el método *Kriging*, implica realizar etapas previas de análisis exploratorio y estructural de los datos (López, 2009). Empleando este método se realizó la interpolación de la concentración de ozono a partir de los tres puntos de muestreo en toda la zona urbana de la ciudad de Victoria de Durango. Se utilizó el método de *Kriging* el cual se reconoce como una herramienta muy útil para interpolar concentraciones de contaminantes atmosféricos con precisión en intervalos espaciales aceptables (Kethireddy *et al.*, 2014). Ya que diversos autores concluyen que este método, realiza los cálculos en función de la variabilidad espacial asegurando la mínima varianza al momento de tomar en cuenta los valores vecinos, y esto arroja mejores resultados al realizar una validación cruzada en los errores de la predicción y el error cuadrático medio (Cañada *et al.*, 2010; Joseph *et al.*, 2013; Michael *et al.*, 2018; Jung *et al.*, 2016).

La interpolación espacial con *Kriging* requiere aplicar un análisis exploratorio de los datos, para esto se revisaron los 24 promedios horarios de las concentraciones de O₃ de las tres estaciones de monitoreo. Estadísticamente, los datos necesitan ser estacionarios y no deben tener ninguna tendencia. Si los datos son estacionarios, la variación de los datos no cambia en las diferentes áreas

del mapa original. Una serie de datos es estacionaria si la media y la variabilidad se mantienen constantes a lo largo del tiempo. La base de datos de O₃ muestran una variación constante a lo largo del año 2019. Con series estacionarias podemos obtener predicciones más certeras. Como la media es constante, podemos estimarla con todos los datos, y utilizar este valor para predecir una nueva observación (Mauricio, 2013). El análisis estructural y predicción se realizó mediante el método *Kriging* ordinario. Con los 24 promedios horarios del mes de mayo, se realizaron 24 interpolaciones correspondientes a las 24 horas del día. La predicción se realizó dentro de la zona urbana de la Ciudad de Durango.

Se estudió la continuidad espacial de la variable. Se calcularon 24 variogramas experimentales para explicar la variabilidad espacial en cada interpolación. El componente de varianza se modela con el variograma, usando la función de covarianza exponencial y tres parámetros de covarianza: el rango (la distancia a la que la correlación espacial existe), umbral parcial (el punto en donde desaparece la correlación entre los puntos) y la pepita (variabilidad no espacial) (Kim *et al.*, 2020).

El método de *Kriging* ordinario predijo en cada lugar una respuesta, ponderando el promedio de los vecinos más cercanos. El método utiliza una transformación de puntuación normal que convierte los datos en una distribución normal estándar. Para estudios básicos, la mejor opción es adoptar el enfoque de *Kriging* (Gisgeography, 2018). El modelo del *Kriging* ordinario es: $Z(s) = \mu + \varepsilon(s)$. Se basa en una media constante de los datos (μ) que no tienen tendencia, y en errores asociados con las predicciones $\varepsilon(s)$ con dependencia espacial. La predicción de un lugar es:

$$Z(s_0) = \sum_{i=1}^N \frac{\lambda_i}{1} z(s_i)$$

Donde: $Z(s_0)$, λ_i es el valor pronosticado de un lugar, es un peso desconocido que se calcula para cada valor observado, y $z(s_i)$ es el valor observado en un lugar. El valor estimado se diferenciará lo menos posible del valor observado, a esa diferencia se le llama error de estimación (Oyala, 2009). Se debe elegir el número máximo y mínimo del radio de búsqueda y se utiliza un algoritmo simple basado en la distancia. Las ponderaciones de *Kriging* provienen del semivariograma que se desarrolló observando la naturaleza espacial de los datos. Realizando predicciones para cada centro de celda en el área de estudio, basadas en el semi variograma y la disposición espacial de los valores medidos que son cercanos, se obtiene la predicción de la concentración del ozono en zonas no

cubiertas por el muestreo (Janssen *et al.*, 2008). Para la determinación de la zona de influencia del ozono se empleó “álgebra de mapas”. Se sumaron las interpolaciones y se obtuvo el promedio en un ráster. Posteriormente se transformó el valor de cada una de las interpolaciones, asignando el valor numérico de uno a aquellos valores que están por encima de la media y con el valor de cero a aquellos valores que están por debajo de la media. De esta manera se consiguió definir la zona de influencia de mayor impacto del contaminante.

A partir de las 24 observaciones resultantes del mes de mayo de 2019 de la variable O₃ y temperatura, se procedió a ingresar o importar la base de datos en el *software* R (RStudio Team, 2019). Se realizaron tres análisis de regresión lineal simple (uno por cada estación de monitoreo). En cada análisis se utilizó como variable dependiente la concentración de O₃ a cada hora del día y a la temperatura como variable independiente. El modelo de regresión lineal simple utilizado se representa bajo la siguiente fórmula:

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

Dónde: Y es la concentración de O₃, β_0 es la altura de corte del eje de las coordenadas Y, β_1 es el incremento en Y según X, X es la temperatura y ε residual o error aleatorio. De los análisis del *software* R, de cada mes, se obtuvo la gráfica de dispersión de las dos variables correlacionadas con la Correlación de Pearson (r), Coeficiente de Determinación (R²) y el Error Cuadrático medio (RMSE).

Resultados y discusión

El promedio horario por mes calculado en las tres estaciones de monitoreo permitió determinar el lapso en que la concentración de O₃ fue máxima y mínima (figs. 2, 3 y 4). El período de descenso coincide con el de medición nocturna, mientras que el de ascenso coincide con el periodo diurno. Las concentraciones más altas se presentaron en la fase con mayor radiación solar del año 2019. Las concentraciones de O₃ suelen ser mayores en los meses de diciembre a mayo que en la temporada de julio a noviembre (Son *et al.*, 2018). En este caso, los meses de estudio incluyen parte de la temporada de sequía (enero a mayo) y un período de meses de lluvia (junio a octubre); los meses de noviembre y diciembre (temporada de frío y sequía) no se incluyeron en el estudio dado que la variación estacional suele separarse en estas dos estaciones, seca y lluviosa (Cano *et*

al., 2016). Se ha demostrado que el contaminante decrece en su concentración entre las 04:00 y 06:00 horas y alcanza su máximo durante el día entre las 12:00 y las 17:00 horas, dependiendo de la radiación y el nivel de contaminación de cada ciudad (Michael *et al.*, 2018 y Gorai *et al.*, 2017). Los niveles más altos se presentan en la estación de monitoreo de la SRNyMA en donde se alcanzan las concentraciones más altas cercanas a 0.040 ppm en el mes de mayo y las más bajas en el mes de octubre de 0.002 ppm.




Fig. 2. Promedio horario de las concentraciones de ozono en partículas por millón en la estación de monitoreo de la SRNyMA.

Fig. 2. Hourly average of ozone concentrations in particle per million at the SRNyMA monitoring station.




Fig. 3. Promedio horario de las concentraciones de ozono en partículas por millón en la estación de monitoreo del CIIDIR.

Fig. 3. Hourly average of ozone concentrations in particle per million at the CIIDIR monitoring station.




Fig. 4. Promedio horario de las concentraciones de ozono en partículas por millón en la estación de monitoreo del ITD.

Fig. 4. Hourly average of ozone concentrations in particle per million at the ITD monitoring station.

Se analizaron las concentraciones máximas de O_3 en el año 2019 y el mes de mayo resultó ser el más alto en concentración de O_3 en las tres estaciones (fig. 5). Las concentraciones máximas varían en el horario de las 13:00 a las 23:00 horas del día. La concentración máxima se encontró en el mes de mayo en las tres estaciones, mientras que en el mes de septiembre se reportó la incidencia más baja de O_3 .




Fig. 5. Promedio de concentraciones máximas de ozono en ppm en la SRNYMA, CIIDIR e IPN.

Fig. 5. Average maximum ozone concentrations in ppm in SRNYMA, CIIDIR e IPN.

Por otro lado, los niveles bajos de concentración de O_3 en aire ambiente no superan los límites máximos permisibles establecidos en la NOM-020-SSA1-2014 (DOF, 2014), la cual establece que la concentración de O_3 debe ser menor o igual a 0.095 ppm como promedio horario; la concentración máxima de O_3 fue de 0.037 ppm en el mes de mayo a las 21 horas. Esta concentración alcanza solo el 19.9 % del límite máximo permisible mencionado. A partir de los datos de la estación de monitoreo del CIIDIR se realizó una rosa de vientos, el viento predominante en el mes de mayo del 2019 tiene una dirección suroeste con una velocidad promedio de 2 a 8 m/s, lo cual favorece la dispersión de los contaminantes en el área de estudio.

Se obtuvo el promedio horario del mes de mayo, es decir, 24 datos referentes a las 24 horas del día, con esto se obtuvieron 24 interpolaciones con el método *Kriging* ordinario, el cual, predijo mediante parámetros automatizados, la concentración de O_3 en el área de estudio. Se calculó la distancia entre los tres puntos de muestreo (tabla 1). Según el Sistema Nacional de Monitoreo Atmosférico, cada estación de muestreo establecida en la zona urbana tiene un área de representatividad de cuatro kilómetros de diámetro (fig. 1).

Tabla 1. Distancia entre las tres estaciones de muestreo.

Table 1. Distance between the three sampling stations.

Mínima	4897 metros
Promedio	7577.4 metros
Máxima	8917.61 metros

Los 24 variogramas experimentales fueron determinados asumiendo condiciones isotrópicas debido al número reducido de puntos de muestreo. A cada semivariograma se le ajustó automáticamente un variograma teórico, los cuales fueron exponenciales en su mayoría. Los modelos exponenciales y esféricos suelen ser los adecuados para variables a nivel del suelo como el O_3 troposférico (López-Rodríguez *et al.*, 2009).

El método de *Kriging* ordinario se consideró como el método óptimo para realizar la predicción de las concentraciones de O_3 en la zona urbana (fig. 6). Este método permitió obtener el error de predicción de las 24 interpolaciones. Como es sabido, el error de predicción aumenta al alejarse de los puntos de las estaciones de muestreo. Se obtuvo el error de predicción promediado de las 24 interpolaciones (fig. 7), el cual alcanza sus valores más altos en la zona sur de la ciudad y

los más bajos en el área de muestreo. El error de predicción es menor en la interpolación realizada a las cuatro de la tarde, donde el error estándar promedio es de 2.07, gradualmente, empieza a aumentar conforme pasan las horas hasta alcanzar su máximo a las 12 am, en donde el error estándar promedio es de 12.36 (tabla 2). Utilizando este mismo método en un estudio realizado en Houston, Texas, se encontró un error de predicción máximo de 15.2 y se concluyó que *Kriging* ordinario arroja resultados adecuados en la distribución espacial, también presenta resultados más realísticos al suavizar la variación espacial del O₃ (Michael *et al.*, 2018).

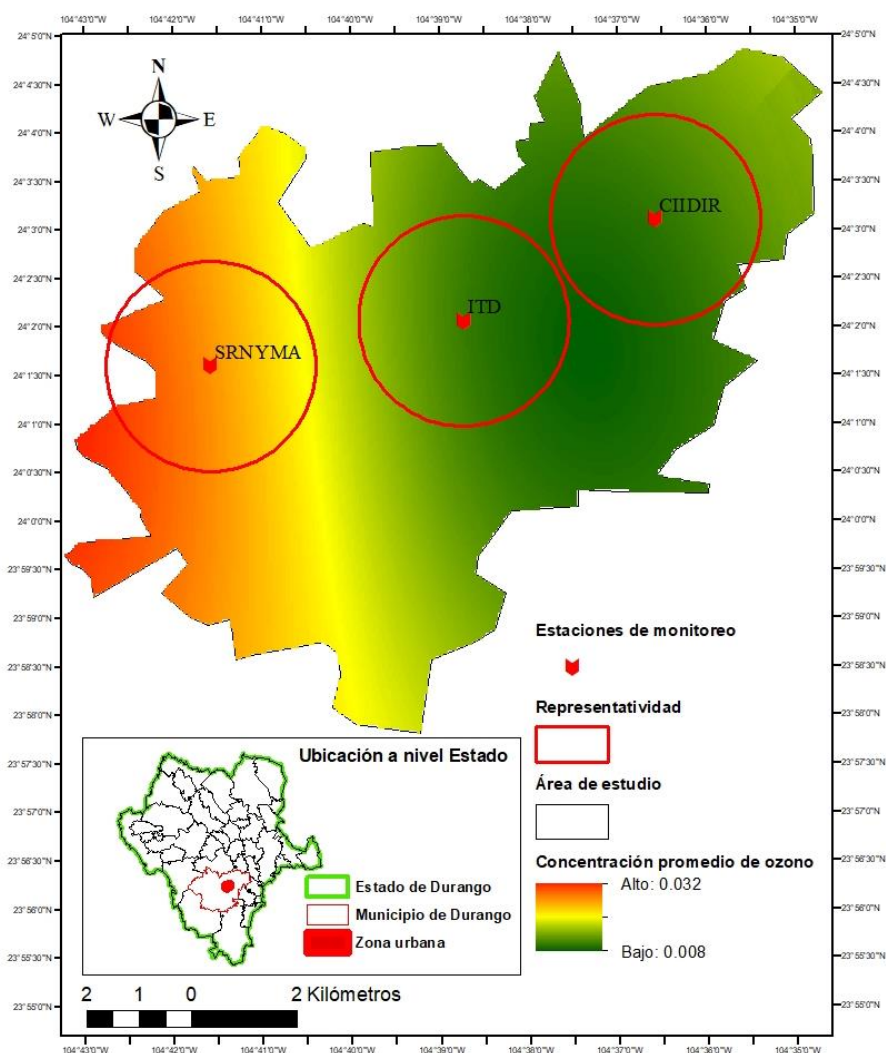


Fig. 6. Promedio de la concentración de ozono en ppm.
Fig. 6. Average ozone concentration in ppm.

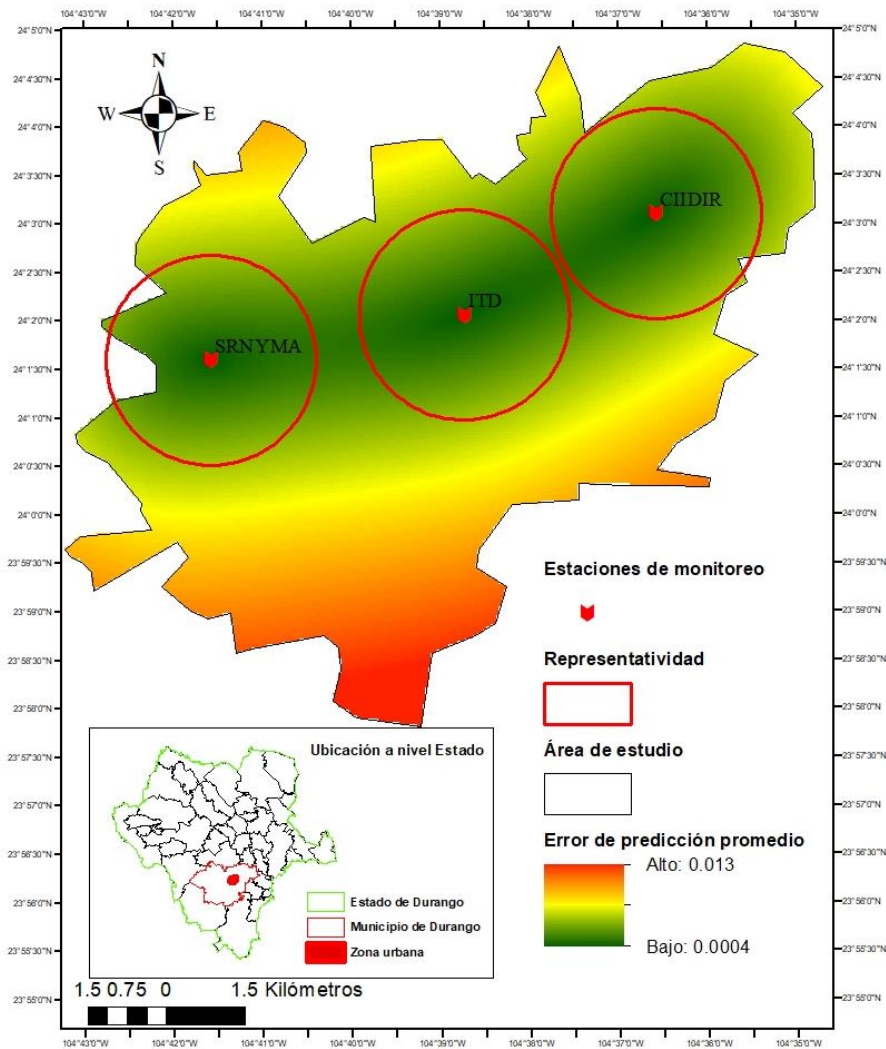


Fig. 7. Error de predicción promedio de las 24 interpolaciones.

Fig. 7. Mean prediction error of the 24 interpolations.

La representatividad de las estaciones coincide con el menor error de predicción promedio obtenido (fig. 7). El buffer creado para cada estación es de dos kilómetros de radio, ocupando en mayor proporción la zona central de la zona urbana. Tomando en cuenta que los valores del error de predicción obtenido representan las mismas unidades de concentración de ozono, es decir, ppm. Se visualiza que dentro del área de confiabilidad de las estaciones el error varía de 0.0004 hasta 0.005 ppm en el área límite de representatividad. Estimar la distribución espacial de los promedios horarios de la concentración de O₃ con el modelo arrojado de *Kriging* ordinario informará en materia de riesgos de salud en la población por la contaminación y puede ser aplicada en modelos predictivos de riesgos a la salud (Michael *et al.*, 2018).

Tabla 2. Parámetros de la predicción.**Table 2.** Prediction parameters.

Muestras	Media	Raíz cuadrada del valor medio	Media estandarizada	Raíz cuadrada del valor medio estandarizado	Error estándar promedio	Hora
3	-1.02	1.99	-0.27	0.90	2.07	4pm
3	-6.36	14.66	-0.27	1.13	12.36	12am

La validación cruzada se utiliza para darle validez a la predicción arrojada por *Kriging* ordinario (Jung *et al.*, 2016). La validación, para las 16:00 horas, arrojó el menor error estándar promedio (tabla 3). Se visualiza que el valor medido y el predicho tienen poca diferencia, a esta hora las concentraciones en las tres estaciones son parecidas. De lo contrario, la validación cruzada a las 12:00 horas presenta un mayor error (tabla 4). Esto se puede deber a la diferencia significativa que se presenta en el valor medido de la SRNYMA (Muestra 1) respecto a las otras dos muestras.

Tabla 3. Validación cruzada a las 16:00 pm.**Table 3.** Cross validation at 4:00 p.m.

Muestras	Valor medido	Valor predicho	Error	Error estándar	Error estandarizado
0	16.62	17.72	1.09	1.25	0.87
1	21.5	18.41	-3.08	2.58	-1.19
2	14.63	13.54	-1.09	2.16	-0.50

Tabla 4. Validación cruzada a las 12:00 pm.**Table 4.** Cross validation at 12:00 p.m.

Muestras	Valor medido	Valor predicho	Error	Error estándar	Error estandarizado
0	9.59	19.36	9.775	8.38	1.16
1	32.4	9.80	-22.59	14.99	-1.50
2	9.08	2.80	-6.27	12.78	-0.49

Se identificaron las zonas en donde el error de predicción rebasa su promedio con base a las 24 interpolaciones (fig. 8). En la zona sur, la más alejada de los tres puntos de muestreo, el error promedio se rebasa de uno a 13 veces, mientras que la zona cero se encuentra dentro del promedio (fig. 7).

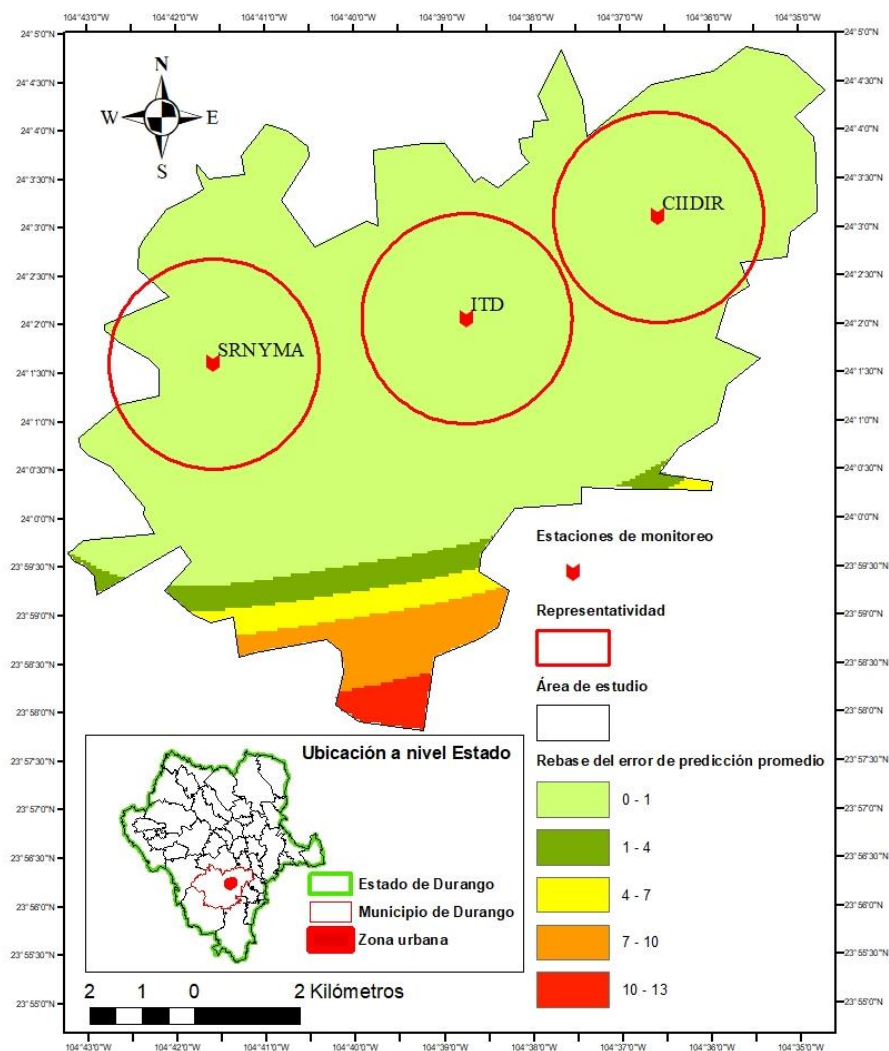


Fig. 8. Rebase del error promedio en las 24 interpolaciones.

Fig. 8. Average error exceedance in the 24 interpolations.

La concentración de O_3 interpolada en *Kriging*, es mayor en la zona poniente de la ciudad. La estación de la SRNYMA registra las mayores concentraciones en esta zona de la ciudad. Esta estación se encuentra rodeada de los dos parques más grandes de la ciudad, así como de zonas de terrenos sin alguna construcción. Lo que coincide con otros estudios en donde los niveles de O_3 fueron mayores en las periferias que en la zona central de la ciudad, debiéndose a la vegetación, la cual aporta precursores del O_3 , como lo son los compuestos orgánicos volátiles (Xie *et al.*, 2019 y Wang *et al.*, 2009). La concentración disminuye en el noroeste de la ciudad, la concentración más alta del promedio se presentó a las nueve de la noche (fig. 9). Al tratarse de solo tres puntos de

muestreo el error de predicción es mayor en las zonas donde no existen otros puntos de muestreo (fig. 10).

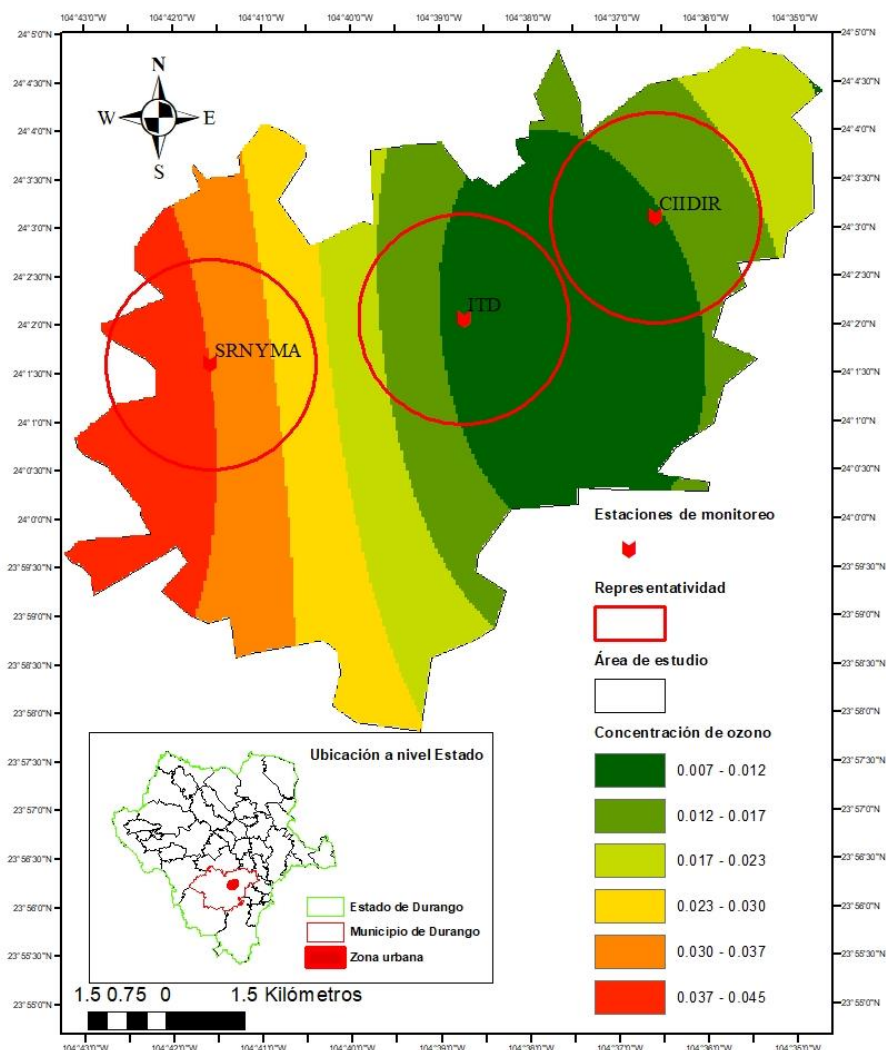


Fig. 9. Interpolación de las concentraciones de ozono a las 9 pm con el método de *Kriging* ordinario.

Fig. 9. Interpolation of ozone concentrations at 9 pm with the ordinary *Kriging* method.

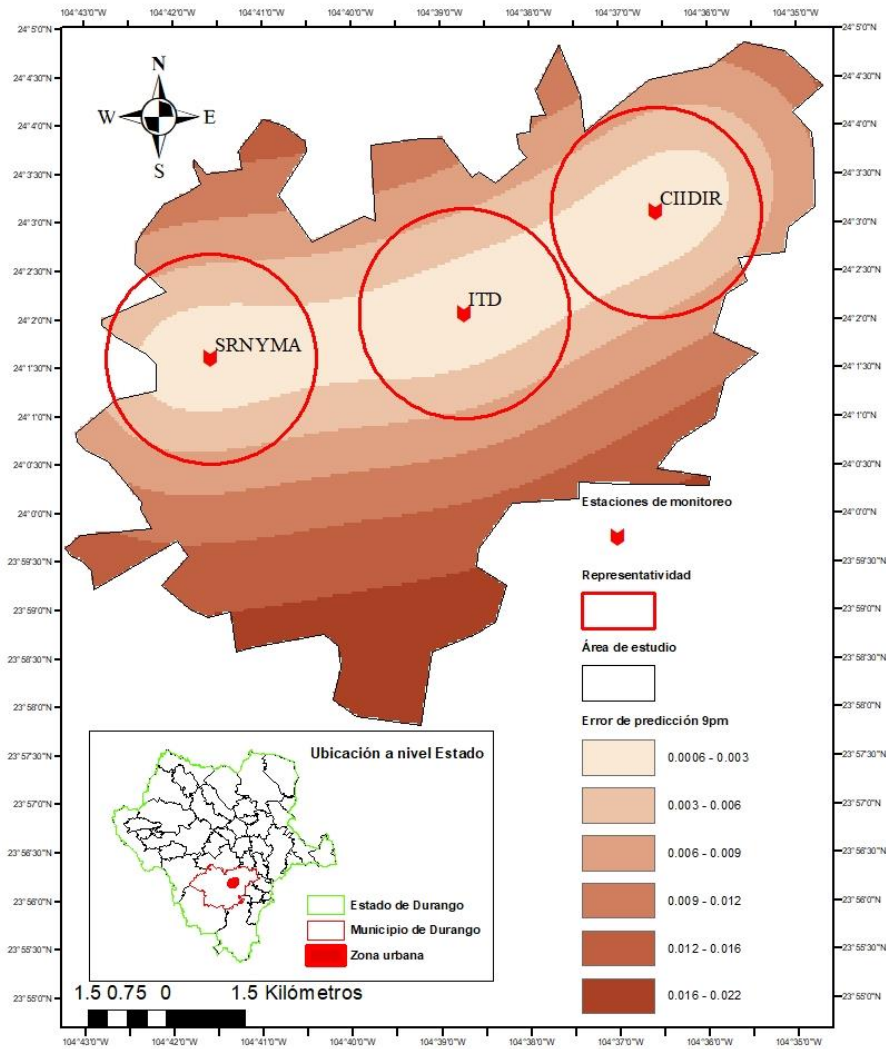


Fig. 10. Error de predicción a las 9 pm con el método de *Kriging* ordinario.

Fig. 10. Prediction error at 9 pm with the ordinary *Kriging* method.

El método *Kriging* ordinario asume que el promedio no es conocido, este se enfoca en el componente espacial y solo utiliza las muestras vecinas para el estimado (Jung *et al.*, 2016). Para las variables analizadas, los parámetros fueron automatizados, es decir, los recomendados por el software. La metodología de *Kriging* empleada en el presente estudio, mostró aplicaciones similares y que se ha empleado para el monitoreo y el procesamiento digital de contaminantes atmosféricos en intervalos espaciales específicos (Kethireddy *et al.*, 2014). Por ejemplo, Joseph *et al.*, (2013) analizaron la distribución del O_3 en verano, comparando los métodos sobre la aplicación de datos de validación para evaluar la interpolación espacial por O_3 , los intervalos más estrechos y el mejor ajuste con los datos de validación (medidos por el RMSE) fueron los de *Kriging* ordinario.

En cuanto a la validación del modelo, *Kriging* esta validación genera información más completa conforme a errores en la predicción y suele obtener una media de los errores de la predicción reducida y un menor error cuadrático medio. (Cañada *et al.*, 2010). Por otra parte, Michael *et al.*, (2018) reporta una mejor representación en cuanto a la consistencia de las superficies generadas, *Kriging* ordinario se determinó como método más preciso, generando menores errores (Raíz del error cuadrático medio y error estándar medio). En otro estudio, el procedimiento *Kriging* arrojó mejores estimaciones en un estudio realizado en Corea del Sur sobre la asociación de la interpolación espacial entre niveles de O_3 y la función pulmonar en residentes de una zona industrial (Jung *et al.*, 2016). Con las interpolaciones realizadas con el método de *Kriging* ordinario y mediante algebra de mapas se determinó la zona de influencia del contaminante. Este polígono representa las áreas donde las concentraciones de O_3 rebasan el promedio horario durante el día (fig. 11).

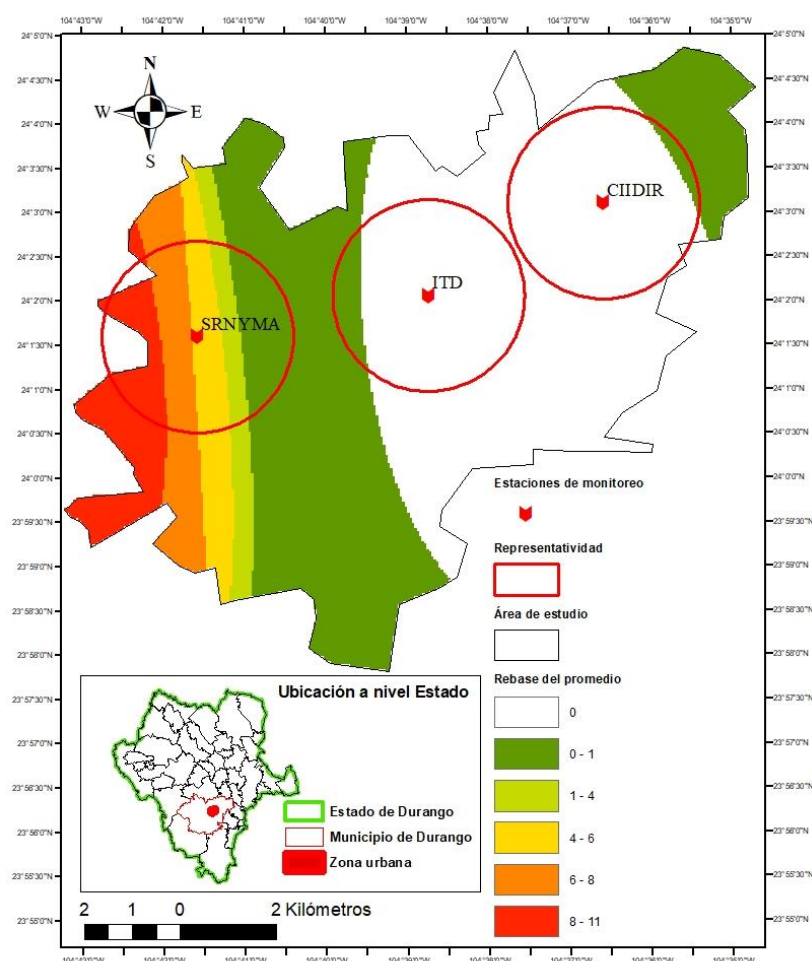


Fig. 11. Zona de influencia.

Fig. 11. Influence zone.

Dentro de la zona de influencia se encontraron 307 escuelas, 81 templos, siete mercados y dos centros comerciales. En estos lugares suelen ser los que concentran mayores grupos de personas en horarios hábiles.

Según el análisis sobre las infecciones respiratorias en 2019 en la ciudad de Durango, las admisiones respiratorias son mayores en los niños de cero a cuatro años y en los adultos de 25 a 44 años (fig. 12). El O₃ asociado significativamente con las consultas a urgencias por afecciones respiratorias, principalmente en niños de cinco años o menores (Hernández-Cadena *et al.*, 2007).




Fig. 12. Población masculina y femenina en el año 2019, admisiones en centros médicos por infecciones respiratorias agudas.

Fig. 12. Male and female population in 2019, admissions to medical centers for acute respiratory infections.

La población relativa al censo 2010 se proyectó al año 2015 de acuerdo con la encuesta intercensal de INEGI (2015). El parámetro que incluye la población más vulnerable por infecciones respiratorias agudas es el rango de población de 25 a 44 años, esta es mayor en el área donde se rebasa solo una vez el promedio horario de O₃, este estrato de población alcanza un máximo de 258 personas por manzana, la mayoría de esta población está distribuida en manzanas de 50 a 70 personas de esta edad (fig. 13). Aparte de representar su distribución espacial por manzana se identificó el total de población de 25 a 44 años por zona de influencia (tabla 6).

Tabla. 6. Población de 25 a 44 años por zona de influencia.
Table. 6. Population aged 25 to 44 years by area of influence.

Zona de influencia	Población de 25 a 44 años	Porcentaje
1	139199	60.03
2	2997	1.29
3	7690	3.31
4	13816	5.95
5	13315	5.74
6	15818	6.82
7	14172	6.11
8	12784	5.51
9	8587	3.7
10	2820	1.21
11	680	0.29
Total	231878	100

El 53.8 % de la población total en el área urbana se encuentra dentro de la zona de influencia. De la población en la zona de influencia el 32.5 % pertenece a este rango de edad. La zona de influencia se encuentra distribuida en áreas donde se rebasa el valor promedio de 0.032 ppm de dos hasta 11 veces en 24 horas.

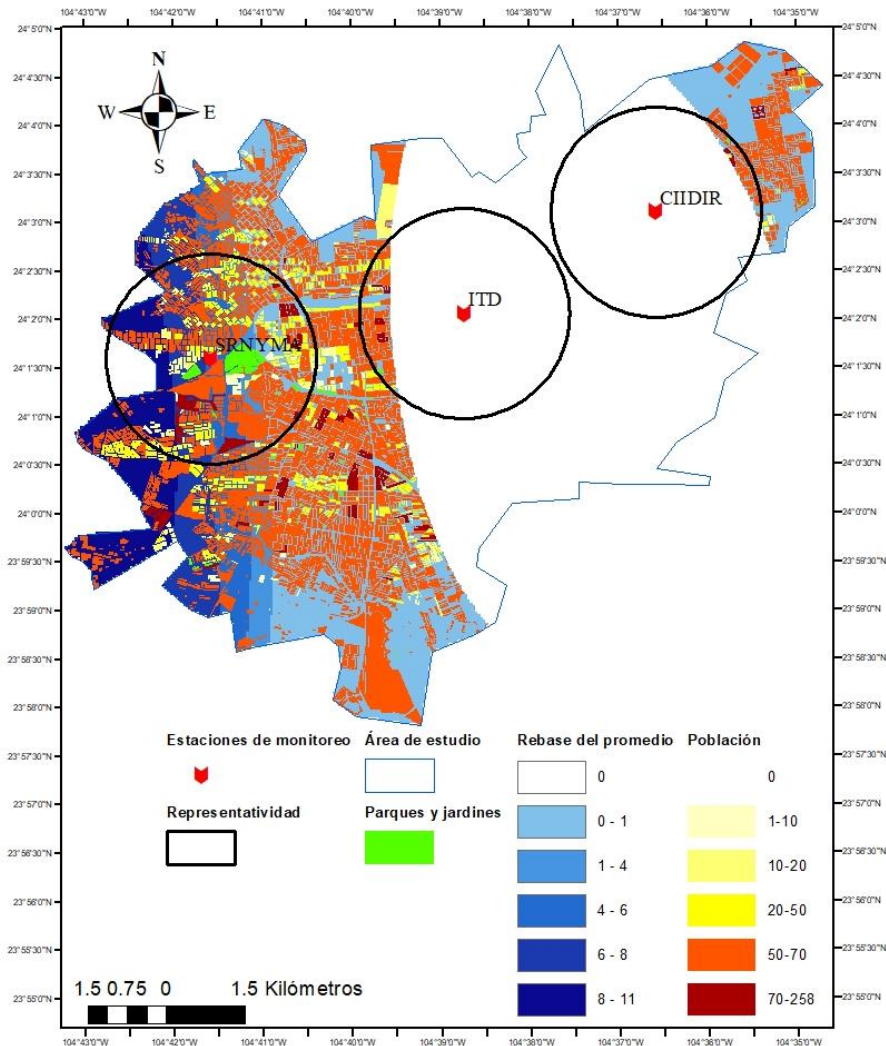


Fig. 13. Población por manzana de 25 a 44 años en zona de influencia por rebase promedio de concentración horaria de ozono.

Fig. 13. Population per block aged 25 to 44 years in the zone of influence due to the average hourly ozone concentration exceeded.

Se muestra la concentración mínima y máxima de O_3 del valor medio en un periodo de ocho horas (fig. 14). En el caso del límite máximo permisible ($Imp = 0.090$ ppm), se consideró lo establecido por la NOM-020-SSA1-2014 como no dañino para la población (DOF, 2014). Los valores máximos registrados ($no > 0.090$ ppm) fueron para la estación de la SRNYMA de 0.090 ppm, una concentración de 0.086 ppm para la estación del ITD y de 0.80 ppm para la estación del CIDIIR. La predicción con el *kriging* ordinario, fue de carácter gaussiano. En la misma figura, se puede observar el área donde los valores superan el límite máximo permisible (0.091), en esta área se encuentra el 8.7 % de la población del rango de edad de 25 a 44 años en la zona urbana.

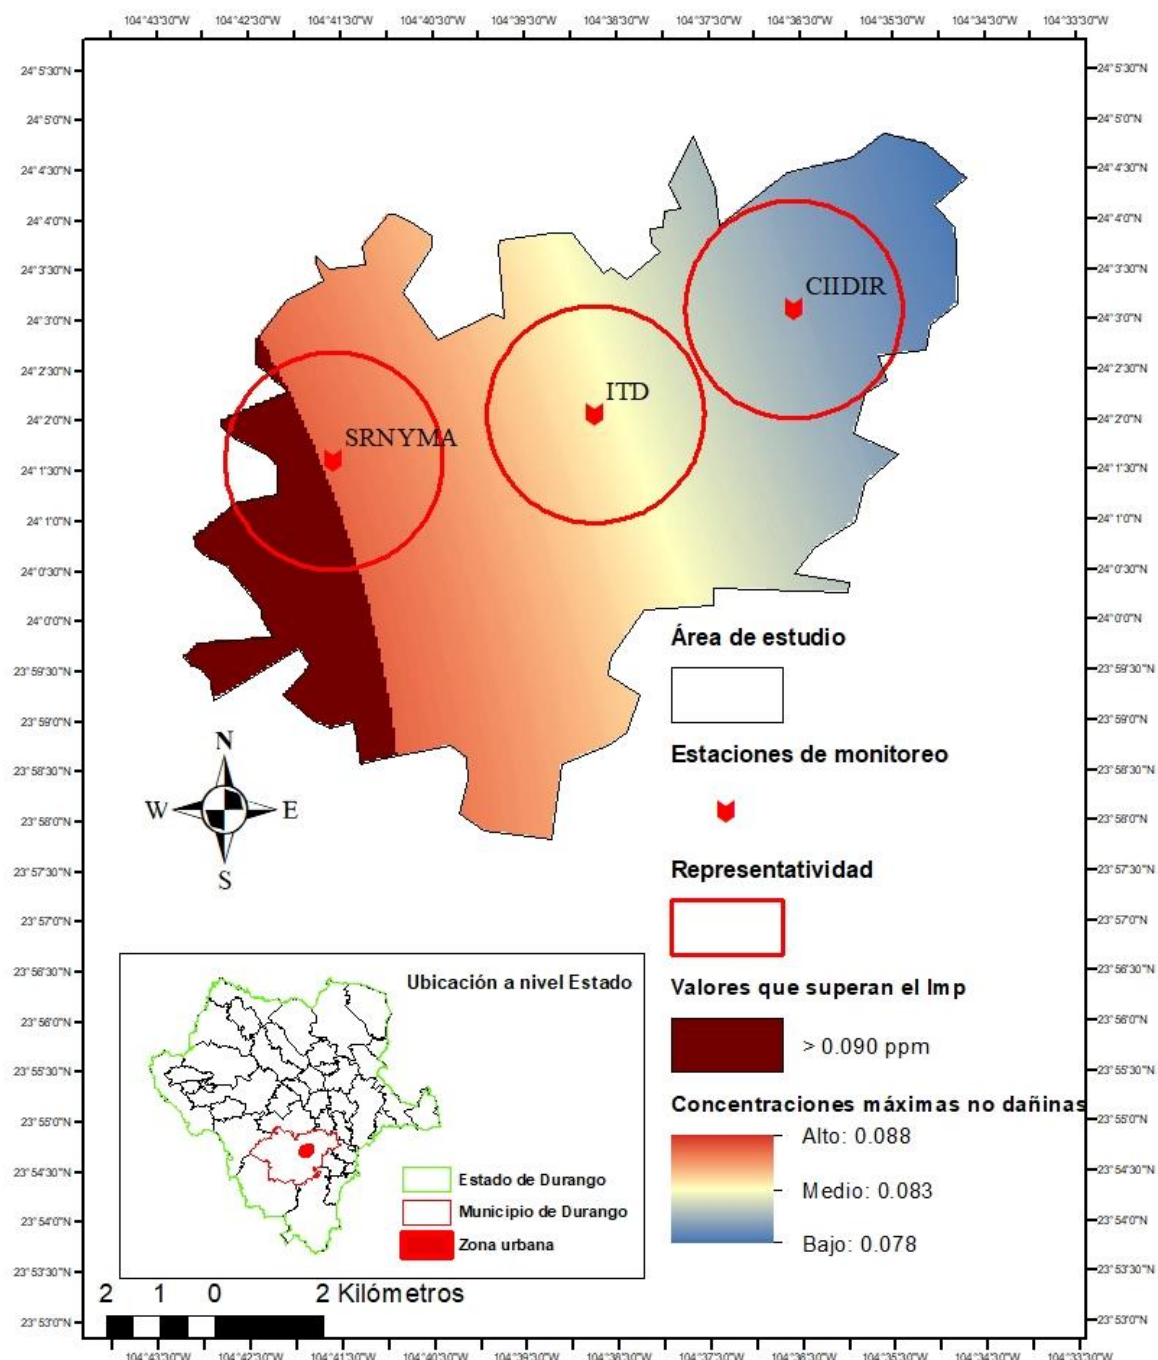


Fig. 14. Concentraciones máximas de O_3 no dañinas en ppm.

Fig. 14. Maximum non harmful O_3 concentrations in ppm.

En el diagrama de correlación de cada estación de monitoreo se representó la relación del ozono con la temperatura mostrándose el perfil de las 24 horas del día. Se aplicó el coeficiente de Pearson para determinar la correlación lineal entre la temperatura y el O_3 , dos variables cuantitativas. Los

diagramas muestran una correlación lineal positiva entre las variables de las estaciones CIIDIR y ITD, mientras que en la estación de la SRNYMA ocurre lo contrario (figs. 15, 16 y 17).




Fig. 15. Diagrama de correlación de la concentración de ozono y la temperatura con datos de la estación de monitoreo de la SRNYMA.

Fig. 15. Correlation diagram of ozone concentration and temperature with data from the SRNYMA monitoring station.

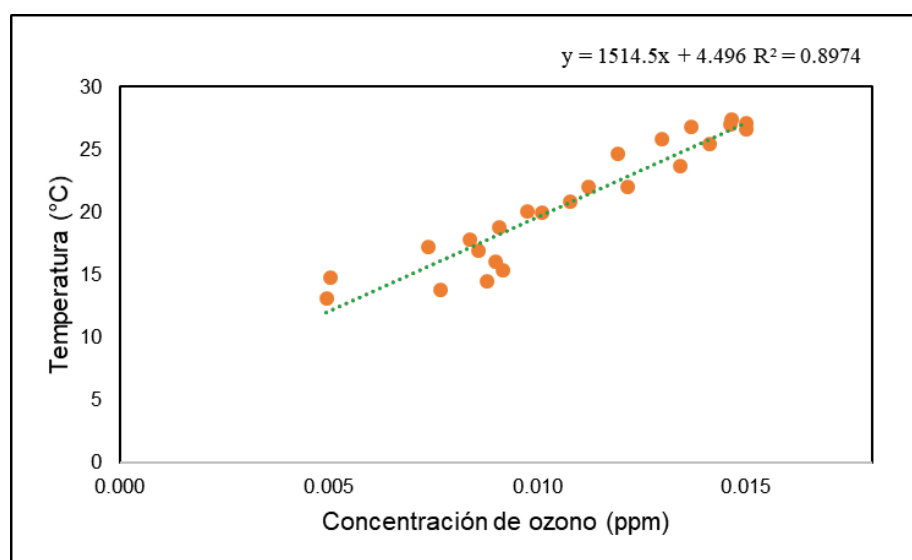


Fig. 16. Diagrama de correlación de la concentración de ozono y la temperatura con datos de la estación de monitoreo del CIIDIR.

Fig. 16. Correlation diagram of ozone concentration and temperature with data from the CIDIIR monitoring station.




Fig. 17. Diagrama de correlación de la concentración de ozono y la temperatura con datos de la estación de monitoreo del ITD.

Fig. 17. Correlation diagram of ozone concentration and temperature with data from the ITD monitoring station.

La comparación de las concentraciones por hora de O_3 con la temperatura presentó una correlación significativa en las estaciones del CIIDIR y del ITD (tabla 7). La correlación más alta se presenta entre las 14:00 y 18:00 horas en las estaciones con relación positiva entre las dos variables. Esto es congruente con lo esperado, debido a que el O_3 es un contaminante secundario de origen fotoquímico y por tanto la radiación solar favorece su formación (Cano *et al.*, 2016 y Malley *et al.*, 2017).

De acuerdo con un estudio realizado en la zona metropolitana de la Ciudad de México, los coeficientes de correlación suelen aumentar y ser positivos en un horario de las 10 a las 18 horas, en donde gradualmente la correlación empieza a decrecer. Los valores máximos de correlación de 0.2 a 0.3 suelen presentarse entre las 15 y 17 horas (Bravo *et al.*, 2000). En India, se reportó un coeficiente de 0.57 en la temporada de junio a septiembre, destacando el mes de mayo con la relación más significativa (Gunthe *et al.*, 2016). También, Gorai *et al.* (2017) reportó un coeficiente de correlación de 0.89 en el mes de mayo para estas variables.

Por otro lado, la estación de SRNYMA a diferencia de CIDIIR e ITD mostró una correlación baja ($r = 0.55$) a comparación de las dos anteriores. Esta estación de monitoreo de SRNYMA está localizada en una zona con influencia de vegetación (los principales parques de la ciudad) (fig. 1) lo que contribuyen a la generación fotoquímica de ozono que es inducida por las emisiones naturales de compuestos orgánicos volátiles (COVB's) a partir de la oxidación del

nitrógeno en la vegetación existente similar a lo mencionado por Jasaitis (2016). Por otro lado, Avino (2008) encontró variaciones de NO_x y O₃ dependiendo de las distintas épocas del año y observo el favorecimiento de condiciones atmosféricas para la acumulación de contaminantes antropogénicos al nivel del piso incrementando la concentración significativamente debido a la ausencia de viento y lluvia. Estas son las condiciones típicas en la ciudad de Durango para este mes en particular, que históricamente es el inicio de la época de sequía en todo el estado.

Otros procesos como el incremento en la turbulencia del aire, la actividad fotoquímica, el incremento en concentración de partículas como los NO_x, SO_x deberán ser analizados respecto a la formación de smog fotoquímico el cual deberá profundizarse en futuros trabajos (Zoran *et al.* 2016).

Tabla 7. Modelo de regresión lineal simple.

Table 7. Simple linear regression model.

Estación de monitoreo	Modelo	r	Error residual estándar	Valor P	R ²	RMSE
CIIDIR	$y = 4.496 + 1514.5 (x)$	0.94	0.99	2.35E-12	0.89	0.48
SRNYMA	$y = 26.395 + 8.4462 (x)$	0.54	4.79	9.00E-04	0.29	8.35
ITD	$y = 8.2838 + 1107.2 (x)$	0.95	1.23	2.18E-13	0.91	0.59

Donde: y = variable dependiente (concentración de ozono); x = variable independiente (Temperatura).

Where: y = dependent variable (ozone concentration); x = independent variable (Temperature).

El R² de 0.89 y 0.91 indica que el modelo explica un 89 y 91 % de la varianza de la variable dependiente, en este caso el ozono para las estaciones del CIIDIR y ITD. El resto de la varianza puede atribuirse a otras variables que no se han incorporado al modelo. Para la estación de SRNYMA se determina una R² 0.29. Cano *et al.*, (2016) encontró una correlación de 0.87 entre estas variables, lo cual sugiere que el aumento de la temperatura durante el día favorece la cinética de formación del O₃.

Conclusión

El ciclo diurno del ozono se analizó mensualmente indicando mayores concentraciones en el mes de mayo. El método *Kriging* ordinario realizó una predicción aceptable de acuerdo con los errores de predicción presentados en otros trabajos, tomando en cuenta el número de estaciones de monitoreo para determinar la zona de influencia en donde se rebasó el promedio de concentración de ozono troposférico. Se encontró una mayor concentración en el lado poniente de la zona urbana,

lo cual indica que es necesario el estudio de otras variables, como el relieve en el área de interés y la generación de precursores biogénicos de O_3 a causa de la vegetación. Tras el análisis de la correlación con un valor 0.54 se considera que la influencia de emanación de COVB's juegan un rol importante en la zona y que deberán ser cuantificados en futuros trabajos, considerando las variables como el viento, humedad relativa, radiación solar, influencia de Nox y el incremento de reactividad fotoquímica como se mostró en el trabajo de *Miller et al. (1994)*. Ya que se tiene aproximadamente 130 hectáreas de extensión de terreno arbolado y que difiere de las otras dos estaciones que se encuentran ubicadas en zonas habitacionales y sin parques cercanos, una de las razones para realizar, una ampliación de este estudio, involucrando la mayor cantidad de variables para poder definir la generación de COVB's de origen antropogénico o biogénico, cercanos al sitio y determinar la relación que la biomasa tendría como principal emisor de precursores de O_3 (*Miller et al. 1994*).

La zona de influencia permitió identificar el total de la población expuesta a los niveles más altos de O_3 en la ciudad. Es posible que la población vulnerable a infecciones respiratorias agudas se pueda ver afectada por la contaminación por ozono, por lo anterior, es necesario contar con bases de datos de salud georreferenciadas para poder relacionar adecuadamente la variable de ozono troposférico y de enfermedades respiratorias. El ozono mostró una correlación positiva de 0.55 a 0.95 con la variable de temperatura. Esta relación indica que los niveles de O_3 en la ciudad dependen significativamente de la temperatura.

Referencias

- Avino, P. Manigrasso, M. (2008). Ten-year measurements of gaseous pollutants in urban air by an open-path analyzer. *Atmospheric environment*, 42(18), 4138–4148.
<https://doi.org/10.1016/j.atmosenv.2008.01.024>
- Basagaña, X., Rivera, M., Aguilera, I., Agis, D., Bouso, L., Elosua, R., y Künzli, N. (2012). Effect of the number of measurement sites on land use regression models in estimating local air pollution. *Atmospheric Environment*, 54, 634–642.
<https://doi.org/10.1016/j.atmosenv.2012.01.064>
- Beauchamp, M., Malherbe, L., de Fouquet, C., Létinois, L., y Tognet, F. (2018). A polynomial approximation of the traffic contributions for kriging-based interpolation of urban air

- quality model. *Environmental Modelling & Software*, 105, 132–152. <https://doi.org/10.1016/j.envsoft.2018.03.033>
- Bello-Medina, PC., Rodríguez-Martínez, E., Prado-Alcalá, RA., y Rivas-Arancibia, S. (2019). Contaminación por ozono, estrés oxidativo, plasticidad sináptica y neurodegeneración. *Neurología*. <https://doi.org/10.1016/j.nrl.2018.10.003>
- Bradley, FJ. (2007). Efecto genotóxico ya la salud en personal expuesto a contaminantes emitidos por ladrilleras en Durango, México. Maestro en Ciencias Ambientales. Victoria de Durango. Centro Interdisciplinario de Investigación para el Desarrollo Integral Regional, Unidad-Durango del Instituto Politécnico Nacional. 90 p: <http://tesis.ipn.mx/handle/123456789/843>
- Bravo, JL., Nava, M., y Muhlia, A. (2000). Relaciones entre la magnitud del valor máximo de ozono, la radiación solar y la temperatura ambiente en la Zona Metropolitana de la Ciudad de México. *Revista Internacional de Contaminación Ambiental*, 16(2). 45-54. <https://www.revistascca.unam.mx/rica/index.php/rica/article/view/32542>
- Cano, YN., Morales, JA., Sánchez, LJ., Colina, MN., y Torres, JC. (2016). Evaluación de niveles de ozono en la ciudad de Maracaibo, Venezuela. *Revista Internacional de Contaminación Ambiental*, 32(1), 25-34. http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-49992016000100025
- Cañada, R., Vidal, MJ., y Moreno, A. (2010). Interpolación espacial y visualización cartográfica para el análisis de la justicia ambiental: ensayo metodológico sobre la contaminación por partículas atmosféricas en Madrid. Sevilla. Tecnologías de la Información Geográfica: La Información Geográfica al servicio de los ciudadanos. Secretariado de Publicaciones de la Universidad de Sevilla. 691-715. <http://hdl.handle.net/10486/669117>
- Cañada, MR., Moreno, A., y González, H. (2015). Modelado de la calidad del aire urbano. Un experimento metodológico con técnicas de interpolación espacial. *Boletín de la Asociación de Geógrafos Españoles*, (65), 317-342. <http://hdl.handle.net/10486/670056>
- Cheng, IK., McDonald, R., y Sandhu, H. (1998). Forest fire enhanced photochemical air pollution. A case study. *Atmospheric Environment*, 32. 673-681. [https://doi.org/10.1016/S1352-2310\(97\)00319-1](https://doi.org/10.1016/S1352-2310(97)00319-1)
- DOF. (2003). Nom-036-Semarnat-1993. Que Establece Los Métodos De Medición Para Determinar La Concentración De Ozono En El Aire Ambiente Y Los Procedimientos Para

- La Calibración De Los Equipos De Medición. Diario Oficial de la Federación. <https://sinaica.inecc.gob.mx/archivo/noms/NOM-036-SEMARNAT-1993.pdf>
- DOF. (2012). NOM-156-SEMARNAT-2012, Establecimiento y operación de sistemas de monitoreo de la calidad del aire. Diario Oficial de la Federación. <https://sinaica.inecc.gob.mx/archivo/noms/NOM-156-SEMARNAT-2012.pdf>
- DOF. (2014). Nom-020-Ssa1-2014, Salud Ambiental. Valor límite permisible para la concentración de Ozono (O₃) En El Aire Ambiente y Criterios para su Evaluación. Diario Oficial de la Federación. <https://sinaica.inecc.gob.mx/archivo/noms/NOM-020-SSA1-2014%20O3.pdf>
- Giraldo, R. (2001). Propuesta de un indicador como variable auxiliar en el análisis *cokriging*. *Revista Colombiana de Estadística*, (24), 1-12. <https://revistas.unal.edu.co/index.php/estad/article/view/28421>
- Gisgeography. (2018). Kriging Interpolation. <https://gisgeography.com/kriging-interpolation-prediction/>
- Gorai, AK., Biswal, SS., y Mitra, G. (2017). Effects of meteorology on ground-level ozone (GLO) concentrations and identifying the hot spots having significantly higher GLO concentration in a semi-urban area. *Environment, Development and Sustainability*, 20(4), 1461–1481. <https://doi.org/10.1007/s10668-017-9947-3>
- Guenther, A. (2000). The contribution of reactive carbon emissions from vegetation to the carbon balance of terrestrial ecosystems, *Chemosphere*, 49, 837–844. [https://doi.org/10.1016/s0045-6535\(02\)00384-3](https://doi.org/10.1016/s0045-6535(02)00384-3)
- Gunthe, SS., Beig, G., y Sahu, LK. (2016). Study of relationship between daily maxima in ozone and temperature in an urban site in India. *Current Science (Bangalore)*, 110(10), 1994-1999. <https://doi.org/10.18520/cs/v110/i10/1994-1999>
- Hernández-Cadena, L., Barraza-Villarreal, A., Ramírez-Aguilar, M., Moreno-Macías, H., Miller, P., Carbajal-Arroyo, LA., y Romieu, I. (2007). Morbilidad infantil por causas respiratorias y su relación con la contaminación atmosférica en Ciudad Juárez, Chihuahua, México. *Salud Publica Mex*, 49, 27-36. http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0036-36342007000100005
- Hoek, G., Beelen, R., de Hoogh, K., Vienneau, D., Gulliver, J., Fischer, P., y Briggs, D. (2008). A review of land-use regression models to assess spatial variation of outdoor air pollution.

Atmospheric Environment, 42(33), 7561–7578.
<https://doi.org/10.1016/j.atmosenv.2008.05.057>

- Janssen, S., Dumont, G., Fierens, F., y Mensink, C. (2008). Spatial interpolation of air pollution measurements using CORINE land cover data. *Atmospheric Environment*, 42(20), 4884–4903. <https://doi.org/10.1016/j.atmosenv.2008.02.043>
- Jasaitis, D., Vasiliauskienė, V., Chadyšienė, R., y Pečiulienė, M. (2016). Surface Ozone Concentration and Its Relationship with UV Radiation, Meteorological Parameters and Radon on the Eastern Coast of the Baltic Sea. *Atmosphere*, 7(2), 27–. <https://doi.org/10.3390/atmos7020027>
- Joseph, J., Sharif, HO., Sunil, T., y Alamgir, H. (2013). Application of validation data for assessing spatial interpolation methods for 8-h ozone or other sparsely monitored constituents. *Environmental Pollution*, 178, 411–418. <https://doi.org/10.1016/j.envpol.2013.03.035>
- Jung, SW., Lee, K., Cho, YS., Choi, JH., Yang, W., Kang, TS., y Son, BS. (2016). Association by Spatial Interpolation between Ozone Levels and Lung Function of Residents at an Industrial Complex in South Korea. *International Journal of Environmental Research and Public Health*, 13(7), 728. <https://doi.org/10.3390/ijerph13070728>
- Kethireddy, S., Tchounwou, P., Ahmad, H., Yerramilli, A., y Young, J. (2014). Geospatial Interpolation and Mapping of Tropospheric Ozone Pollution Using Geostatistics. *International Journal of Environmental Research and Public Health*, 11(1), 983–1000. <https://doi.org/10.3390/ijerph110100983>
- Kim, Sun-Young., Bechle, M., Hankey, S., Sheppard, L., Szpiro, AA., Marshall, JD., y Giorgi, E. (2020). Concentrations of criteria pollutants in the contiguous U.S: Role of prediction model parsimony in integrated empirical geographic regression. *PLOS ONE*, 15(2). <https://doi.org/10.1371/journal.pone.0228535>
- Lee, EH. (2003). Use of auxiliary data for spatial interpolation of surface ozone patterns. *Developments in Environmental Science*, 165–194. [https://doi.org/10.1016/S1474-8177\(02\)02007-7](https://doi.org/10.1016/S1474-8177(02)02007-7)
- Lopez-Rodríguez, F., Moral, FJ., y Valiente, P. (2009). Evaluation and analysis of the urban air pollution by means of the use of geostatistical techniques and geographical information systems (SIG). Selected *Proceedings from the 13th International Congress on Project Engineering*, 227-234. <https://dialnet.unirioja.es/servlet/articulo?codigo=3309514>

- Malley, CS., Henze, DK., Kuylenstierna, JCI., Vallack, HW., Davila, Y., Anenberg, SC., y Ashmore, MR. (2017). Updated Global Estimates of Respiratory Mortality in Adults ≥ 30 Years of Age Attributable to Long-Term Ozone Exposure. *Environmental Health Perspectives*, 125(8), 087021. <https://doi.org/10.1289/EHP1390>
- Mauricio, JA. (2013). Introducción al análisis de series temporales. Universidad Complutense de Madrid. (En línea). Consultado 15 mayo, 2021. Disponible en <https://www.ucm.es/data/cont/docs/518-2013-11-11-JAM-IASST-Libro.pdf>
- Michael, R., O'Lenick, CR., Monaghan, A., Wilhelmi, O., Wiedinmyer, C., Hayden, M., y Estes, M. (2018). Application of geostatistical approaches to predict the spatio-temporal distribution of summer ozone in Houston, Texas. *Journal of Exposure Science & Environmental Epidemiology*. <https://doi.org/10.1038/s41370-018-0091-4>
- Miller, PR., Bauer, MDL., Nolasco, AQ., y Tejeda, TH. (1994). Comparison of ozone exposure characteristics in forested regions near Mexico City and Los Angeles. *Atmospheric Environment*, 28(1), 141-148. [https://doi.org/10.1016/1352-2310\(94\)90029-9](https://doi.org/10.1016/1352-2310(94)90029-9)
- Olaya, V. (2009). Sistemas de información geográfica. *Cuadernos internacionales de tecnología para el desarrollo humano*, (8), 15. <http://hdl.handle.net/2099/7584>
- Organización Mundial de la Salud. (OMS). (2018). Salud y calidad del aire. [http://www.who.int/es/news-room/fact-sheets/detail/ambient-\(outdoor\)-air-quality-and-health](http://www.who.int/es/news-room/fact-sheets/detail/ambient-(outdoor)-air-quality-and-health)
- Rodríguez-Fernández, P., Prat-Aymerich, C., y Domínguez, J. (2019). Interaction Between Environmental Pollution and Respiratory Infections. *Archivos de Bronconeumología (English Edition)*, 55(7), 351–352.
- Team, RC. (2019). RStudio: Integrated Development for R. RStudio, Inc., Boston, MA URL <http://www.rstudio.com/>.
- Shukla, K., Kumar, P., Mann, GS., y Khare, M. (2019). Mapping spatial distribution of particulate matter using Kriging and Inverse Distance Weighting at supersites of megacity Delhi. *Sustainable Cities and Society*. <https://doi.org/10.1016/j.scs.2019.101997>
- Son, Y., Osornio-Vargas, ÁR., O'Neill, MS., Hystad, P., Texcalac-Sangrador, JL., Ohman-Strickland, P., y Schwander, S. (2018). Land use regression models to assess air pollution exposure in Mexico City using finer spatial and temporal input parameters. *Science of The Total Environment*, 639, 40–48. <https://doi.org/10.1016/j.scitotenv.2018.05.144>

- Tian, Y., Wu, Y., Liu, H., Si, Y., Wu, Y., Wang, X., y Wu, T. (2020). The impact of ambient ozone pollution on pneumonia: A nationwide time-series analysis. *Environment International*, 136, 105498. <https://doi.org/10.1016/j.envint.2020.105498>
- Weather Spark. (2019). Weather Spark: El clima promedio en Victoria de Durango (en línea, sitio web). Consultado 23 de abril, 2020. Disponible en <https://es.weatherspark.com/y/3659/Clima-promedio-en-Victoria-de-Durango-M%C3%A9xico-durante-todo-el-a%C3%B1o#Sections-Summary>
- Wang, X., Li, J., Zhang, Y., Xie, S., y Tang, X. (2009). Ozone source attribution during a severe photochemical smog episode in Beijing, China. *Science in China Series B: Chemistry*, 52(8), 1270-1280. <https://doi.org/10.1007/s11426-009-0137-5>
- Xie, Y., Dai, H., Zhang, Y., Wu, Y., Hanaoka, T., y Masui, T. (2019). Comparison of health and economic impacts of PM_{2.5} and ozone pollution in China. *Environment International*, 130, 104881. <https://doi.org/10.1016/j.envint.2019.05.075>
- Zhao, X., Cheng, H., He, S., Cui, X., Pu, X., y Lu, L. (2018). Spatial associations between social groups and ozone air pollution exposure in the Beijing urban area. *Environmental Research*, 164, 173–183. <https://doi.org/10.1016/j.envres.2018.02.014>
- Zoran, M., Dida, MR., y Savastru, R. (2014). Ground level ozone (O₃) associated with radon (²²²Rn) and particulate matter (PM) concentrations in Bucharest metropolitan area and adverse health effects. *J Radioanal Nucl Chem*, 300, 729–746. <https://doi.org/10.1007/s10967-014-3041-1>