



Universidad Nacional Autónoma de México

Instituto de Ciencias de la Atmósfera y Cambio Climático

Proyecto SECTEI-168-2022

Componente 1. Climatología y meteorología

Actividad 1.6 Desarrollo de pronóstico de calidad del aire mediante Redes Neuronales.

Reporte Final: Enero 2024

Pedro A. Segura Chávez, Olmo Zavala Romero, Jorge Zavala Hidalgo, Pavel Oropeza Alfaro, Rosario Romero Centeno

Introducción

La predicción de niveles de contaminantes como del ozono troposférico es una tarea compleja debido a los factores que inciden en la generación y acumulación del contaminante.

Diferentes factores influyen en los niveles de ozono troposférico como las condiciones meteorológicas, y factores relacionados con las fuentes de emisiones de ozono y sus precursores que están relacionados a la actividad humana, como la actividad industrial y el transporte, entre otras fuentes [1].

La Zona Metropolitana del Valle de México (ZMVM) es una de las regiones más altamente pobladas en el mundo por lo que presenta grandes retos para el control de niveles de contaminantes atmosféricos como es el caso del ozono atmosférico [1,2].

La ZMVM ha reducido significativamente los niveles de contaminantes atmosféricos con la implementación de diferentes programas gubernamentales, sin embargo, aún quedan tareas para el control y reducción de contaminantes atmosféricos.

Nuevas herramientas y soluciones, como mejores pronósticos, son importantes para predecir episodios con altos niveles de contaminación. Dichos pronósticos pueden aportar información valiosa a los tomadores de decisiones en la gestión de alertas. En este sentido en este proyecto se trabaja en el desarrollo y puesta en marcha de un pronóstico operativo basado en redes neuronales para la predicción de niveles de ozono.

Modelos basado en redes neuronales y aprendizaje automático

En el modelado de problemas complejos es difícil extraer características abstractas y de alto nivel de datos en bruto, esto, debido a que las características para ser aprendidas requieren una alta compresión de los datos y para extraer características en el modelo [3].

Por otro lado, en el aprendizaje profundo se busca resolver este problema con la introducción de representaciones de características en términos de características más simples. Es decir, un sistema de aprendizaje profundo puede representar un concepto combinando conceptos o funciones más simples.

Una red profunda de perceptrón multicapa (MLP) es una arquitectura que permite aprender algunas características que requieren una alta compresión de los datos para extraer características en el modelo.

Un perceptrón multicapa es una función matemática que mapea un conjunto de valores de entrada a valores de salida. La función se compone de muchas funciones más simples que proveen nuevas representaciones de los valores de entrada. Estas redes, con múltiples capas,

son capaces de capturar relaciones complejas y abstractas. En la Figura 1. Se muestra un esquema de una red neuronal multicapa donde se inicia con un capa de neuronas de entrada, y se conectan con más capas de neuronas internas hasta una capa de salida [2].




Figura 1. Esquema de una red neuronal perceptrón multicapa: la red neuronal comienza con una capa de entrada (neuronas verdes). Las neuronas están conectadas a múltiples capas ocultas, indicadas por neuronas intermedias rosas. Las conexiones, marcadas por líneas, representan los pesos sinápticos que ajustan la importancia de las señales entre las neuronas. Finalmente, la red converge en una capa de salida (neuronas azules).

Objetivos

La actividad tiene como objetivo proporcionar un pronóstico de concentración de ozono para las próximas 24 horas utilizando aprendizaje automático, basado en observaciones históricas de los niveles de contaminantes y del pronóstico meteorológico.

Datos

Para el desarrollo del pronóstico se usaron datos de de niveles de ozono de la red RAMA y datos de un pronóstico meteorológico WRF.

La Red Automática de Monitoreo Atmosférico (RAMA), forma parte del del Sistema de Monitoreo Atmosférico de la Ciudad de México (SIMAT)[4], la red lleva a cabo mediciones ininterrumpidas cada minuto desde el año 1986 de varios contaminantes, que incluyen ozono (O3), dióxido de azufre (SO2), óxidos de nitrógeno (NOx), monóxido de carbono (CO), partículas de menos de 10 y 2.5 micrómetros (PM10 y PM2.5), y ácido sulfhídrico (H2S) [5]. Los promedios diarios horarios de estos contaminantes para la Zona Metropolitana del Valle de

México se recopilan y publican por la dirección de monitoreo atmosférico, para base de datos de entrenamiento y validación se usaron los datos publicados en la dirección http://www.aire.cdmx.gob.mx/aire/estadisticas-consultas/concentraciones. En la Figura 2. Se muestran los datos registrados por la estación Merced (MER) de la red RAMA del año 2010 a 2010 a 2020.

*En este trabajo se usa la unidad de concentración **ppb** que es coincidente con 1 ppm x 10^3




Figura 2. Serie temporal de los niveles horarios de ozono observados de 2010 a 2020 para la estación Merced (MER) del inventario de la RAMA.

Se consideraron 30 estaciones con datos de la Red Automática de Monitoreo Atmosférico que se listan en la Tabla 1 a continuación, y su ubicación se muestra en la Figura 3.

Clave	Nombre	Latitud	Longitud
UIZ	UAM Iztapalapa	19.36°	-99.07°
AJU	Ajusco	19.27°	-99.21°
ATI	Atizapan	19.57°	-99.25°
CUA	Cuajimalpa	19.36°	-99.29°
SFE	Santa fe	19.36°	-99.26°
SAG	San Agustin	19.53°	-99.03°
CUT	Cuautitlán	19.72°	-99.20°
PED	Pedregal	19.32°	-99.20°

TAH	Tlahuac	19.25°	-99.01°
GAM	Gustavo A. Madero	19.48°	-99.09°
IZT	Iztacalco	19.38°	-99.12°
CCA	Centro de Ciencias de la Atmósfera	19.33°	-99.18°
HGM	Hospital General de México	19.41°	-99.15°
LPR	La Presa	19.53°	-99.12°
MGH	Miguel Hidalgo	19.40°	-99.20°
CAM	Camarones	19.47°	-99.17°
FAC	FES Acatlán	19.48°	-99.24°
TLA	Tlalnepantla	19.53°	-99.20°
MER	Merced	19.42°	-99.12°
XAL	Xalostoc	19.53°	-99.08°
LLA	Los Laureles	19.58°	-99.04°
TLI	Tultitlán	19.60°	-99.18°
UAX	UAM Xochimilco	19.30°	-99.10
BJU	Benito Juárez	19.37°	-99.16°
MPA	Milpa Alta	19.20°	-99.01°
MON	Montecillo	19.46°	-98.90°
NEZ	Nezahualcóyotl	19.39°	-99.03°
INN	Investigaciones Nucleares	19.29°	-99.38°

Tabla 1. La tabla de estaciones de la red RAMA usadas en modelo de pronóstico.




Figura 3. Localización de estaciones que se están considerando de la Red Automática de Monitoreo Atmosférico (RAMA).

Pronóstico WRF

Adicionalmente a los datos de la red RAMA, se usa el pronóstico numérico de la atmósfera generado con el modelo Weather Research & Forecasting (WRF) [6,7]. Para el pronóstico operativo y entrenamiento se usa la implementación del modelo operativo del Grupo Interacción Océano-Atmósfera (IOA) del ICAyCC de la UNAM que tiene en funcionamiento operacional, así como inventarios del grupo IOA de modelos de reanálisis WRF.

"La configuración del modelo WRF implementada utiliza como condiciones iniciales y de frontera, las 00Z del modelo Global Forecast System (GFS), con resolución temporal de 3 horas y espacial de 0.25 grados. La malla de los dominios del modelo utiliza una proyección Mercator, con 50 niveles verticales y un paso de tiempo adaptativo que permite que el modelo se ejecute de forma más eficiente. Para la cobertura y uso del suelo se utilizan los datos del INEGI, mismos que fueron reclasificados para homologar con la clasificación utilizada por el Servicio Geológico de los Estados Unidos (USGS)." [8] Datos adicionales de la implementación del modelo WRF se detallan en [8].

Metodología

En el desarrollo de modelos basados en redes neuronales, iteramos en la experimentación con variables de entrada, preprocesamiento de datos y ajuste de hiperparámetros para optimizar el rendimiento. Se realizaron experimentos para desarrollar un modelo para predecir los niveles

de contaminantes para diferentes número de horas, con el objetivo de predecir hasta 24 horas hacia adelante.

Los scripts para correr el modelo se pueden encontrar en el repositorio https://github.com/olmozavala/air pollution forecast/

Preparación del Ambiente:

El software corre con la version 3.10 de Python. Se utilizó el framework de aprendizaje automático desarrollado por Google, TensorFlow 2.0. TensorFlow es una plataforma de desarrollo de software de fuente abierta con licencia Apache 2.0 para el desarrollo de modelos de aprendizaje automático e inteligencia artificial. Este framework puede usarse en diferentes plataformas, sistemas operativos, y permite el desarrollo con múltiples CPUs y GPUs con CUDA [10]. Se generaron Jupyter notebooks para facilitar la descripción y visualización de los resultados en el desarrollo y experimentación.

Los cálculos y entrenamientos del modelo se corren en el servidor ZION del ICAyCC de la UNAM que consiste en un sistema multi GPU con cuatro tarjetas gráficas Nvidia GeForce GTX 1080 a 1.6 GHz y 8 GB de RAM, con doble procesador Intel Xeon E52630 a 2.4 GHz con 8 núcleos por socket y 64 GB de RAM.

Fuentes de datos:

Para el entrenamiento, se prepararon bases de datos desde el año 2010 hasta el año 2019, y se consideraron 10% de los datos para la validación del modelo. Para la base de datos de prueba independiente se usa el año 2022.

En la experimentación se incluyeron los niveles de los diferentes contaminantes de la red RAMA, variables meteorológicas obtenidas del modelo operativo WRF del grupo Interacción Océano Atmósfera del ICAyCC de la UNAM, y se generan variables armónicas de los tiempos registrados para considerar temporalidad de los datos, donde el año, mes, día, día de la semana de la medición se expresó como senos, y cosenos y como medios senos y cosenos [9], en la Tabla 1 se muestra las variables usadas en la versión final.

Fuente de datos / característica	Descripción
Datos históricos de RAMA O₃	Niveles de ozono O₃ por hora de las estaciones RAMA.

WRF U10	Velocidad del viento zonal a 10 metros.
WRF V10	Velocidad del viento meridional de 10 metros.
WRF RAINC	Precipitación acumulada (convectiva).
WRF RAINNC	Precipitación acumulada (no convectiva).
WRF T2	Temperatura a 2 metros.
WRF SWDOWN	Flujo de radiación de onda corta descendente.
WRF GLW	Flujo de radiación de onda larga descendente.
Armónicos de tiempo	Codificación senoidal y cosenoidal de la hora/día, día/semana y día/año.

Tabla 2. Tabla de variables consideradas para el modelo de pronóstico con redes neuronales.

Flujo de Trabajo para entrenamiento:

El flujo de trabajo para el entrenamiento, se ilustra en la Figura 4, resume los procesos principales desde la configuración de datos hasta la fase de entrenamiento del modelo y su evaluación.




Figura 4. Diagrama de flujo para el entrenamiento del modelo.

El flujo de trabajo involucra la transformación de datos de salidas del modelo WRF y niveles de contaminantes de la RAMA a formatos CSV. Posteriormente, se fusionan estos datos en archivos CSV por año para el entrenamiento. A continuación se describen los pasos generales del proceso de entrenamiento.

- Se comienza configurando los archivos *TrainingUserConfiguration.py* que se encuentra en el directorio ./conf/ del repositorio.
- Se establecen años de entrenamiento y validación y parámetros del modelo.
- Se preparan archivos intermedios CSV.

Preprocesado DBWRF->CSV

En el preprocesado de datos del WRF se prepara un CSV para el entrenamiento con el script (1_MakeCSV_From_WRF.py). Las variables se extraen para una región cuadrada que abarca la Zona Metropolitana del Valle de México. En esta región se define un grid de 16 puntos 4x4 puntos a lo largo y a lo ancho de la región cuadrada.

El grid de 4x4 considerado en el modelo corresponde con la región comprendida entre las latitudes: 18.75 y 20 y en longitud entre: -99.75 y -98.5.

Los valores en los netcdf del pronóstico WRF se interpola a 16 puntos igualmente espaciados de un grid rectangular, y en estos puntos se extraen 24 horas pronosticadas de las variables de interés. Las variables se guardan en archivos CSV.

Preprocesado DBRAMA->CSV

En este proceso se prepara un CSV con los datos que se desean en base de datos de la RAMA guardados en una base de datos postgresQL.

El preprocesado se lleva a cabo con el script llamado "2_MakeCSV_From_DB.py" crea archivos CSV a partir de una base de datos SQL con los niveles de contaminantes horarios de la RAMA y de la configuración general especificada en el archivo (TrainingUserConfiguration). El proceso para generar lso archivos CSV se realiza con el script 2_MakeCSV_From_DB.py

- Fusión de CSVs. En este paso se fusionan los archivos CSV con el script 3 MergeData.py.
 - Se leen configuración del usuario para obtener los datos de las horas previstas tanto de los datos meteorológicos del WRF, y de contaminantes. Se filtran las fechas, se combinan los datos meteorológicos y de contaminantes, y se almacenan en archivos CSV por año.
- Preprocesado entrenamiento: Los siguientes pasos de pre procesamientos se realizan en jupyter notebooks o python scripts específicos para el experimento y entrenamiento objetivo.
 - Se cargan las configuraciones del experimento/modelo.
 - Se divide la base de datos en conjunto de entrenamiento y conjunto de prueba.
 - Se establecen porcentajes de datos de entrenamiento para la validación durante el entrenamiento.
 - Se añaden variables armónicas temporales.
 - Se ajustan variables para el experimento como añadir variables de niveles de contaminantes de horas previas.
 - Se remueven variables meteorológicas en caso de ser necesario.
 - Se ajustan parámetros de remuestreo bootstrap en base de datos.
 - Se ajustan fechas para que se pueda generar los vectores X de entradas y se genera la salida Y considerando los niveles de horas futuras presentes en base de datos.
 - Se normalizan variables con uso de la librería scikit-learn.
 - Se instancia el modelo y se configura de acuerdo a las necesidades del experimento.
- Se corre entrenamiento.
- Se calculan rutinas de evaluación con base de datos de prueba y con las salidas del modelo recién entrenado.
- Se guardan variables resultantes y gráficos.

Modelo

Las características del modelo para el pronóstico operativo se establecieron de la siguiente manera.

Modelo: Red neuronal profunda perceptrón multicapa, esquematizada en la Figura 5.

Número de entradas de Entrenamiento: 238,455.

Número de entradas de Validación: 8,764.

Capa de Entrada: 3,450 columnas de entrada.

Primera Capa Densa: 300 neuronas, con 1,035,300 parámetros.

• Segunda Capa Densa: 300 neuronas, 90,300 parámetros.

■ Batch Normalization: 1,200 parámetros.

■ **Dropout**: Rate 0.2

Tercera Capa Densa : 90,300 parámetros adicionales

■ Batch Normalization: 1,200 parámetros.

■ **Dropout**: Rate 0.2.

Cuarta Capa Densa : 300 neuronas

■ Batch Normalization: 1,200 parámetros.

■ **Dropout**: Rate 0.2.

Capa de Salida: Vector de salida de 720 neuronas, con 216,720 parámetros.

Parámetros Totales del Modelo: 1,524,720 parámetros entrenables con 1,800 neuronas.




Figura 5. Diagrama de arquitectura de la red neuronal perceptron multicapa.

En el vector de entrada (capa de entrada) se incluyeron horas previas de niveles de ozono: en el vector de entrada del modelo se incluyen 24 horas previas de niveles de contaminantes de todas las estaciones, esto busca proveer a la red neuronal a contexto temporal de niveles de los niveles de ozono previos.

Para el entrenamiento se usó el optimizador Adam con parámetros de aprendizaje: learning rate lr=0.0001, y con los demás argumentos por defecto.

Bootstrap: Se implementó el preprocesado denominado bootstrap. En este proceso los datos más extremos de la base de datos se remuestrearon. Este remuestreo permite que el modelo tenga mayor exposición a datos poco frecuentes durante el entrenamiento, como es el caso de valores de niveles altos de ozono. Se remuestrearon los valores extremos que presentan valores normalizados de ozono por encima de 2.9 unidades arbitrarias y que corresponde con aproximadamente el 3% de los valores más altos de ozono presentes en la base de datos de

entrenamiento. El remuestreo consistió en amplificar estos datos específicos por un factor de 15.

En los archivos anexos X_columns.csv, y Y_columns.csv se especifican los nombres de las variables de entrada y salida de la red neuronal.

Métricas de evaluación

Utilizamos varias estadísticas y medidas para evaluar el rendimiento de predicción de nuestro modelo de pronóstico. Error medio absoluto (MAE), Raíz del error cuadrático medio (RMSE), Índice de concordancia (IOA), Coeficiente de determinación (R2), Índice de correlación(CC). A continuación se muestran las fórmulas de las métricas usadas. Para el cálculo de las métricas se usan los niveles de ozono observados o_i y los valores pronosticados p_i para todo el conjunto de datos de prueba [11, 12].

Error medio absoluto (MAE)

El Error Medio Absoluto provee la diferencia promedio en magnitud en las mismas unidades que las observaciones entre predicciones y valores observados, y se calcula como:

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |o_i - \hat{p}_i|$$

Raíz del error cuadrático medio (RMSE)

El RMSE provee una diferencia entre valores predichos y observados en las mismas unidades que las observaciones elevando al cuadrado las diferencias individuales para eliminar los signos negativos:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (o_i - p_i)^2}$$

Coeficiente de determinación (R2)

El R² es un indicador de la bondad de ajuste en modelos, un valor de R² cercano a 1 sugiere que los modelos son más precisos, y se calcula como:

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (o_{i} - p_{i})^{2}}{\sum_{i=1}^{n} (o_{i} - \bar{o})^{2}}$$

Índice de correlación (CC)

El índice o coeficiente de correlación entre valores observados y predicciones, mide la relación lineal entre valores predichos y observados, un alto nivel del índice cercano a 1 sugiere que en la evaluación del modelo los datos observados y predicciones tienen buena correspondencia, o mala correspondencia en caso de valores negativos.

$$CC = \frac{\sum_{i=1}^{n} (o_i - \bar{o})(p_i - \bar{p})}{\sqrt{\sum_{i=1}^{n} (o_i - \bar{o})^2 \sum_{i=1}^{n} (p_i - \bar{p})^2}}$$

Índice de concordancia (IoA)

El índice de concordancia [12] se usa como indicador del grado de similitud entre predicciones de un pronóstico y sus datos observados. Un valor cercano a 1, sugiere que los datos del modelo se asemejan a los datos observados, se calcula como:

$$IoA = 1 - \frac{\sum_{i=1}^{n} (o_i - p_i)^2}{\sum_{i=1}^{n} (|p_i - \bar{o}| + |o_i - \bar{o}|)^2}$$

Resultados

Se calcularon los pronósticos para su evaluación, en la Figura 6 se muestran niveles de ozono pronosticados para las primeras horas de base de datos de evaluación para la estación MER Merced.




Figura 6. Pronóstico vs valores observados de estación Merced (MER) a partir de las 0 horas del 2 de enero de 2022, pronóstico a 12 horas.

En el documento Anexo A1 se muestran los histogramas de densidad hexagonal obtenidos para todas las estaciones, así como sus métricas de los pronósticos obtenidas por estación a diferentes horas.

A continuación en las Figuras 7-11, se muestran gráficos de dispersión con las métricas obtenidas para el vector Y, todas las estaciones y las diferentes horas de predicción .




Figura 7. Métrica de error absoluto medio (MAE) por columna del vector de salida del pronóstico, de izquierda a derecha los pronósticos a 1 hora hasta 24 horas de todas las estaciones, donde el sufijo plus hora, indica el número de hora pronosticada.




Figura 8. Métrica de raíz del error cuadrático medio (RMSE) por columna del vector de salida del pronóstico, de izquierda a derecha los pronósticos a 1 hora hasta 24 horas de todas las estaciones, donde el sufijo plus_hora, indica el número de hora pronosticada.




Figura 9. Métrica de índice de correlación por columna de los 720 valores del vector de salida del pronóstico, de izquierda a derecha los pronósticos a 1 hora hasta 24 horas de todas las estaciones, donde el sufijo plus_hora, indica el número de hora pronosticada.




Figura 10. Coeficiente de determinación (R²) por columna del vector de salida del pronóstico, de izquierda a derecha los pronósticos a 1 hora hasta 24 horas de todas las estaciones, donde el sufijo plus_hora, indica el número de hora pronosticada, la clave de la estación UIZ se muestra de manera indicativa.




Figura 11. Métrica de índice de concordancia (IoA) por columna del vector de salida del pronóstico, de izquierda a derecha los pronósticos a 1 hora hasta 24 horas de todas las estaciones, donde el sufijo plus_hora, indica el número de hora pronosticada, la clave de la estación UIZ se muestra de manera indicativa.

De las gráficas anteriores se observa que las mejores métricas para los pronósticos a la hora más próxima pronosticada, con un error absoluto medio en el mejor de los casos cercano a 6 ppb.

Métricas de pronóstico por estación

A continuación en las Figuras 12-21 se muestran las métricas agrupadas por estación considerando todas las horas pronosticadas.




Figura 12. Métricas de error absoluto medio (MAE) para las diferentes estaciones pronosticadas.




Figura 13. Métrica raíz del error cuadrático medio (RMSE) para las diferentes estaciones pronosticadas.




Figura 14. Métricas de coeficiente de determinación (R²) para las diferentes estaciones pronosticadas.




Figura 15. Métricas de índice de correlación (CC) para las diferentes estaciones pronosticadas.




Figura 16. Métricas de índice de concordancia (IoA) para las diferentes estaciones pronosticadas.

Métricas de pronóstico por hora de pronóstico (todas las estaciones)

A continuación se muestran las métricas calculadas por hora del pronóstico considerando todas las estaciones.




Figura 17. Métricas de error absoluto medio (MAE) por hora considerando los pronósticos de todas las estaciones.




Figura 18. Métrica raíz del error cuadrático medio (RMSE) por hora considerando los pronósticos de todas las estaciones.




Figura 19. Métricas de coeficiente de determinación (R²) por hora considerando los pronósticos de todas las estaciones.




Figura 20. Métricas de índice de correlación (CC) por hora considerando los pronósticos de todas las estaciones.




Figura 21. Métricas de índice de concordancia (IoA) por hora considerando los pronósticos de todas las estaciones.

Métricas globales del pronóstico

En la tabla 3 se muestran las diferentes métricas consideradas, considerando todos los resultados de la evaluación.

Métrica	Valor
MAE	9.8 ppb
RMSE	12.9 ppb
R ²	0.73
Índice de correlación	0.88
Índice de concordancia	0.91

Tabla 3. Métricas globales del modelo para base de datos de prueba.

Evaluación de incertidumbres del pronóstico

Para la evaluación de incertidumbres, se calcularon los errores del pronóstico de niveles máximos diarias, así como los errores del pronóstico de niveles promedio diarios, considerando todas las estaciones, en la Figura 22, se muestra la distribución de errores de los valores máximos diarios (Errors MaxVal 24h), y los errores de los promedios diarios (Errors Mean 24h).




Figura 22. Distribución de errores de valor promedio diario (Errors Mean 24h), y errores de valor pronosticado máximo diarios (Errors MaxVal 24h). En el caso de los errores promedio diarios observamos una distribución centrada cerca del cero (-0.25) lo que sugiere que no hay sesgo apreciable en este caso. En el caso de los errores máximos diarios se observa que la distribución se centra en 9.09, lo que sugiere un sesgo en el modelo a subpronosticar los valores máximos diarios.

Probabilidades P_hist de superar umbrales en interfaz web del pronóstico

Se definieron probabilidades indicativas de superar ciertos umbrales de niveles de ozono denominadas P_hist y que se basan en la distribución de errores históricos del pronóstico en la base de datos de prueba.

Esta probabilidad se calcula definiendo un delta necesario que, cuando se añade al valor pronosticado para las próximas 24 horas, resulta en la superación de umbrales de ozono específicos. La fórmula está dada por:

max(Vpronosticado24horas) + ΔNecesario > Umbral

Donde max(Vpronosticado24horas) es el valor máximo que se tiene pronosticado para las siguientes 24 horas. Umbral, es el umbral de interés para el que se quiere estimar una probabilidad P_hist de superarlo. ΔNecesario es la cantidad adicional o menor que se necesita para que el valor pronosticado supere el umbral de interés.

Se realizó el ajuste de una distribución normal a la distribución de errores máximos diarios y errores promedio diarios del modelo, donde se observa un comportamiento muy cercano al de una distribución normal, como se muestra en la Figura 22.

Se calcula P_hist como la probabilidad de que un aumento ΔNecesario exceda el umbral de ozono de interés. Esta probabilidad se basa en la función de densidad acumulativa normalizada, utilizando los parámetros mu y sigma, que describen la distribución de los datos observados.

Para caso de la probabilidad de tener promedios de 8 horas que superen 50 ppbs

Se determinó el promedio máximo que se encuentra en ventanas de 8 horas para las siguientes 24 horas pronosticadas (Vpromedio/8horas), y se determina un delta necesario de la forma:

max(Vpromedio/8horas) + ΔNecesario > Umbral

De manera similar a los casos anteriores, se usa una distribución normal de errores, pero en este caso ajustada a los valores promedios diarios, Figura 22. Con base en la distribución se estima la probabilidad de un Δ Necesario para superar el umbral de 50 ppb.

Interfaz web de consulta del pronóstico operativo de niveles de ozono

Se implementó una interfaz para la consulta del pronóstico. El pronóstico se encuentra publicado en la dirección:

https://aire.atmosfera.unam.mx/

En la Figura 23, se muestra la interfaz web del pronóstico operativo. En la Figura 24 se detalla la sección con el gráfico de serie de tiempo con los valores pronosticados, y últimos niveles de ozono observados.



Figura 23. Captura de pantalla de interfaz web del pronóstico de ozono operativo. La interfaz está compuesta de un gráfico de serie de tiempo de niveles de ozono. Se muestran detalles del pronóstico mostrado, menú para cambiar de estación e indicadores de probabilidades de exceder umbrales de ozono. Nota: Si el navegador muestra una advertencia de sitio no seguro, haga caso omiso a la advertencia para proceder al pronóstico.




Figura 24. Gráfico de serie de tiempo de niveles de ozono. Se muestra estación seleccionada (La presa, LPR) y hora de pronóstico. En el gráfico se muestran 24 horas previas de observaciones cuando están disponibles, las siguientes 24 horas pronosticadas con el modelo de redes neuronales.

En la Figura 25. se muestra la sección de indicadores de probabilidades.

Probabilidad P_hist de superar umbrales en siguientes 24 hrs.




Figura 25. Gráfico de indicadores de probabilidad. El gráfico muestra la probabilidad P_hist de sobrepasar dentro de las siguientes 24 horas diferentes umbrales de interés:

a) Probabilidad P_hist tener medias mayores a 50 ppbs en periodos de 8 horas. b)

Probabilidad P_hist de superar el umbral de 90 ppb. c) Probabilidad P_hist de superar el umbral de 120 ppb. d) Probabilidad de superar el umbral de 150 ppb.

Ejemplo de predicción en episodio de alto y bajo nivel de ozono

A continuación se muestran ejemplos ilustrativos del tipo de predicciones de niveles altos de ozono por el pronóstico operativo. En la Figura 26 se muestra el pronóstico del 5 de Mayo de 2023, a las 9 am.






Figura 26. Niveles pronosticados para el 6 de mayo de 2023.

Estación MER - Merced a las 2023-05-06 09:00 Probabilidad P_hist de superar umbrales en hrs. siguientes 24 hrs.




Figura 27. Niveles observados el 6 de mayo de 2023 (serie de tiempo izquierda, línea azul), donde se observó un nivel máximo de 115 ppb.

En la Figura 27 se muestran los niveles de ozono medidos para la fecha pronosticada. Se observa una discrepancia entre los valores pronosticados y los reales. Los niveles excedieron el umbral de 90 ppb, alcanzando 115 ppb el 6 de enero, tal como indicaba la probabilidad histórica (P_hist) del 95% correspondiente al 5 de mayo. No obstante, el límite de 120 ppb no fue rebasado, a pesar de estimarse un 80% de probabilidad de que esto ocurriera.

A continuación en la Figura 28 se muestra el pronóstico para días con niveles bajos de ozono. Se muestra el pronóstico del 16 de diciembre de 2023 a las 9am, donde se pronostica un nivel máximo de 41 ppb para el día siguiente. En la Figura 29, se muestra la interfaz web del día siguiente, en este caso se observan diferencia entre los valores observados y pronosticados, donde se tuvo un nivel máximo observado de 35 ppb.

Estación MER - Merced a las 2023-12-16 09:00 Probabilidad P_hist de superar umbrales en hrs. siguientes 24 hrs.




Figura 28. Niveles pronosticados para el 17 de diciembre de 2023, donde se pronostica un nivel máximo de 41 ppb.

Estación MER - Merced a las 2023-12-17 09:00 Probabilidad P_hist de superar umbrales en hrs. siguientes 24 hrs.



Figura 29. Niveles observados el 17 de diciembre de 2023 (izquierda, azul). Se observó un nivel máximo de 35 ppb.

Conclusión y alcances del pronóstico

Se desarrolló un modelo de pronóstico basado en redes neuronales que estima los niveles de ozono en 30 estaciones de la RAMA. El modelo es capaz de pronosticar niveles de ozono para las próximas 24 horas en cada estación respecto a la hora del cálculo.

El modelo se corre en servidores del ICAyCC, UNAM usando los datos de la RAMA que alimentan una base de datos SQL en un servidor del ICAyCC de donde después son requeridos para las tareas de preprocesado en el entrenamiento o para el cálculo del pronóstico operativo.

En el modelo operativo se usan los últimos pronósticos meteorológicos WRF calculados en clúster de alto rendimiento Ometeotl del ICAyCC, generalmente el último pronóstico se termina de calcular en las primeras horas del día (entre 2 am y 6 am), y se usa durante todo el día para alimentar el pronóstico de ozono operativo.

En modelos basados en aprendizaje automático, el modelo se entrena a partir de datos que son expuestos en la fase de entrenamiento, por lo que el modelo muestra una mayor eficiencia con datos similares a los con los que fue entrenado. En caso de que los datos de entrada al modelo sean muy diferentes a los datos de entrenamiento, se suele perder precisión en los valores pronosticados.

El modelo desarrollado es resiliente con la falta de algunos datos en la RAMA, el modelo tiene la capacidad de pronosticar aún con algunas horas de datos faltantes, sin embargo, en caso de intervalos sin datos en toda la red por varias horas (más de 2 horas en las últimas 24 horas) no se puede llevar a cabo el cálculo del pronóstico operativo.

El coeficiente de determinación R^2 de 0.73 que se obtiene en promedio para el pronóstico se puede considerar bueno, sin embargo, en este valor se tiene variabilidad importante de un 27%, que indica variabilidades que el modelo no predice correctamente, por lo que hay espacio para mejoras del pronóstico.

Futuras mejoras pueden en el pronóstico pueden incluir uso de diferentes variables meteorológicas no consideradas o que no se pudieron incluir en esta versión, el uso de arquitecturas de inteligencia artificial más avanzadas, y nuevas fuentes de datos como imágenes de satélite, imágenes de radares, y datos de tráfico vehicular.

Consideramos que es necesario continuar con la evaluación de los valores pronosticados por el modelo operativo y de las probabilidades P_hist para comprobar su utilidad y precisión con los últimos datos, así como ante cambios que puedan tener lugar en la red RAMA.

Referencias

- [1] Peralta, O., Ortínez-Alvarez, A., Torres-Jardón, R., Suárez-Lastra, M., Castro, T., Ruíz-Suárez, L. G. (2021). Ozone over Mexico City during the COVID-19 pandemic. Science of the Total Environment, 761, 143183.
- [2] Guevara, M., Tena, C., Soret, A., Serradell, K., Guzmán, D., Retama, A., ... & Mediavilla, A. (2017). An emission processing system for air quality modelling in the Mexico City metropolitan area: Evaluation and comparison of the MOBILE6.2-Mexico and MOVES-Mexico traffic emissions. Science of The Total Environment, 584, 882-900.
- [3] Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). Deep learning [http://www.deeplearningbook.org]. *MIT Press, Cambridge, MA*.
- [4] Gobierno de la Ciudad de México. (s.f.). Red Automática de Monitoreo Atmosférico.
 Consultado en diciembre de 2023, https://datos.cdmx.gob.mx/base de
 datos/red-automatica-de-monitoreo-atmosferico
- [5] Secretaría de Medio Ambiente y Recursos Naturales. (s.f). Monitoreo de la calidad del aire en la ZMVM. Gobierno de México. Consultado en diciembre de 2023, https://www.gob.mx/semarnat/articulos/monitoreo-de-la-calidad-del-aire-en-la-zmvm
- [6] Skamarock, W. C., Klemp, J. B., Dudhia, J., Gill, D. O., Barker, D. M., Duda, M. G., ...
 & Wang, W. (2008). Powers JG A Description of the Advanced Research WRF Version
 3. NCARTech. Note, 475.
- [7] Mesoscale & Microscale Meteorology Laboratory, National Center for Atmospheric Research. (s.f.). Weather Research & Forecasting Model (WRF). Consultado en diciembre de 2023, https://www.mmm.ucar.edu/models/wrf
- [8] Grupo Interacción Océano-Atmósfera, Universidad Nacional Autónoma de México. (s.f.). Información WRF. Consultado: diciembre de 2023, de http://grupo-ioa.atmosfera.unam.mx/pronosticos/index.php/meteorologia/inf-wrf
- [9] Zavala, O. (2023). Función generateDateColumns en air_pollution_forecast. GitHub repository. Disponible en:
 https://github.com/olmozavala/air_pollution_forecast/blob/allcont_incsv/proj_io/inout.pv

- [10] Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S.,
 ... & Zheng, X. (2015). TensorFlow: Large-scale machine learning on heterogeneous systems. https://www.tensorflow.org/
- [11] Gotway, J. H., Bullock, R., Oldenburg, P., Jensen, T., Holland, L., Brown, B., Fowler, T., Ahijevych, D., & Gilleland, E. (Marzo de 2011). Model Evaluation Tools Version 3.0.1 (METv3.0.1). Development Testbed Center, Boulder, Colorado, USA.
- [12] Willmott, C. J. (1981). On the validation of models. Physical Geography, 2(2), 184-194.

Respuestas a Observaciones por Parte de la SEDEMA al Tercer Reporte de Actividades Parciales

Q1. ¿Se comparó con lo que realiza el área de monitoreo de SEDEMA?

• R1. Se tomó en cuenta el pronóstico de la SEDEMA de manera informativa. Sin embargo, no se encontró publicación acerca del desempeño del pronóstico operativo que nos permita realizar una comparación con nuestro modelo.

Q2. ¿Cómo apoyaría esto a un mejor desempeño del pronóstico de SEDEMA?

 R2. Los pronósticos basados en redes neuronales pueden servir como herramientas adicionales a los modelos actuales usados por la SEDEMA. Al operar con un enfoque diferente, el modelo basado en redes neuronales puede ofrecer una perspectiva complementaria valiosa en el pronóstico de niveles de ozono a 24 horas.

Q3. Con base en qué criterios se definió que los datos para realizar el entrenamiento sean de las últimas 24 horas?

 R3. Se experimentó con diferentes arquitecturas, así como con diferentes datos de entrada, y esta configuración dio resultados notables a la vez que ofreció un buen balance entre número de datos a asimilar y sin que resulte en un vector de entrada demasiado grande. Por ejemplo, se probó con 48 horas y no se observó mejora apreciable en las métricas.

Q4. ¿El pronóstico se puede ampliar a más horas?

 R4. De momento no es posible. El pronóstico en su versión actual está fijado para pronosticar hasta 24 horas siguientes a la hora del pronóstico. En futuras mejoras se puede buscar explorar la ampliación a más horas pronosticadas y la evaluación de su desempeño.

Q5. ¿Se contempla un ejercicio para algún episodio de contingencia?

 R5. Aunque el enfoque inicial no ha incluido específicamente escenarios de contingencia, en el reporte final se incluyen ejemplos ilustrativos del pronóstico operativo para días con altos niveles de ozono y para días con niveles bajos.

Q6. ¿En qué consiste esta metodología bootstrap y cómo se desarrolla el análisis con el componente de meteorología?

 R6. La metodología bootstrap, aplicada en nuestro análisis, implica un proceso de remuestreo enfocado en mejorar la representación de muestras extremas dentro del conjunto de datos de entrenamiento. Donde el 3% de datos extremos se remuestrea por un factor de 15. En el análisis mostrado en el tercer reporte, se evaluó el desempeño del modelo bajo configuraciones distintas: con y sin el proceso de bootstrap, y con la inclusión o exclusión de variables meteorológicas. Esto permitió comparar el impacto de estas variables y del remuestreo con modelos entrenados.

Anexo: Gráficos de densidad hexagonal, y resumen de métricas




Figure 1: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación AJM para año de prueba.




Figure 2: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación AJM para año de prueba.




Figure 3: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación AJM para año de prueba.




Figure 4: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación AJM para año de prueba.




Figure 5: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación AJM para año de prueba.




Figure 6: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación AJU para año de prueba.




Figure 7: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación AJU para año de prueba.




Figure 8: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación AJU para año de prueba.




Figure 9: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación AJU para año de prueba.




Figure 10: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación AJU para año de prueba.




Figure 11: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación ATI para año de prueba.




Figure 12: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación ATI para año de prueba.




Figure 13: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación ATI para año de prueba.




Figure 14: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación ATI para año de prueba.




Figure 15: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación ATI para año de prueba.




Figure 16: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación BJU para año de prueba.




Figure 17: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación BJU para año de prueba.




Figure 18: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación BJU para año de prueba.




Figure 19: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación BJU para año de prueba.




Figure 20: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación BJU para año de prueba.




Figure 21: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación CAM para año de prueba.




Figure 22: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación CAM para año de prueba.




Figure 23: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación CAM para año de prueba.




Figure 24: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación CAM para año de prueba.




Figure 25: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación CAM para año de prueba.




Figure 26: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación CCA para año de prueba.




Figure 27: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación CCA para año de prueba.




Figure 28: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación CCA para año de prueba.




Figure 29: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación CCA para año de prueba.




Figure 30: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación CCA para año de prueba.




Figure 31: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación CUA para año de prueba.




Figure 32: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación CUA para año de prueba.




Figure 33: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación CUA para año de prueba.




Figure 34: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación CUA para año de prueba.




Figure 35: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación CUA para año de prueba.




Figure 36: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación CUT para año de prueba.




Figure 37: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación CUT para año de prueba.




Figure 38: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación CUT para año de prueba.




Figure 39: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación CUT para año de prueba.




Figure 40: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación CUT para año de prueba.




Figure 41: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación FAC para año de prueba.




Figure 42: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación FAC para año de prueba.




Figure 43: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación FAC para año de prueba.




Figure 44: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación FAC para año de prueba.




Figure 45: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación FAC para año de prueba.




Figure 46: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación GAM para año de prueba.




Figure 47: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación GAM para año de prueba.




Figure 48: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación GAM para año de prueba.




Figure 49: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación GAM para año de prueba.




Figure 50: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación GAM para año de prueba.




Figure 51: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación HGM para año de prueba.




Figure 52: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación HGM para año de prueba.




Figure 53: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación HGM para año de prueba.




Figure 54: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación HGM para año de prueba.




Figure 55: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación HGM para año de prueba.




Figure 56: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación INN para año de prueba.




Figure 57: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación INN para año de prueba.




Figure 58: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación INN para año de prueba.




Figure 59: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación INN para año de prueba.




Figure 60: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación INN para año de prueba.




Figure 61: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación IZT para año de prueba.




Figure 62: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación IZT para año de prueba.




Figure 63: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación IZT para año de prueba.




Figure 64: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación IZT para año de prueba.




Figure 65: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación IZT para año de prueba.




Figure 66: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación LLA para año de prueba.




Figure 67: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación LLA para año de prueba.




Figure 68: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación LLA para año de prueba.




Figure 69: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación LLA para año de prueba.




Figure 70: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación LLA para año de prueba.




Figure 71: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación LPR para año de prueba.




Figure 72: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación LPR para año de prueba.




Figure 73: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación LPR para año de prueba.




Figure 74: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación LPR para año de prueba.




Figure 75: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación LPR para año de prueba.




Figure 76: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación MER para año de prueba.




Figure 77: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación MER para año de prueba.




Figure 78: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación MER para año de prueba.




Figure 79: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación MER para año de prueba.




Figure 80: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación MER para año de prueba.




Figure 81: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación MGH para año de prueba.




Figure 82: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación MGH para año de prueba.




Figure 83: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación MGH para año de prueba.




Figure 84: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación MGH para año de prueba.




Figure 85: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación MGH para año de prueba.




Figure 86: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación MON para año de prueba.




Figure 87: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación MON para año de prueba.




Figure 88: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación MON para año de prueba.




Figure 89: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación MON para año de prueba.




Figure 90: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación MON para año de prueba.




Figure 91: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación MPA para año de prueba.




Figure 92: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación MPA para año de prueba.




Figure 93: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación MPA para año de prueba.




Figure 94: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación MPA para año de prueba.




Figure 95: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación MPA para año de prueba.




Figure 96: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación NEZ para año de prueba.




Figure 97: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación NEZ para año de prueba.




Figure 98: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación NEZ para año de prueba.




Figure 99: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación NEZ para año de prueba.




Figure 100: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación NEZ para año de prueba.




Figure 101: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación PED para año de prueba.




Figure 102: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación PED para año de prueba.




Figure 103: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación PED para año de prueba.




Figure 104: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación PED para año de prueba.




Figure 105: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación PED para año de prueba.




Figure 106: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación SAG para año de prueba.




Figure 107: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación SAG para año de prueba.




Figure 108: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación SAG para año de prueba.




Figure 109: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación SAG para año de prueba.




Figure 110: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación SAG para año de prueba.




Figure 111: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación SFE para año de prueba.




Figure 112: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación SFE para año de prueba.




Figure 113: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación SFE para año de prueba.




Figure 114: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación SFE para año de prueba.




Figure 115: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación SFE para año de prueba.




Figure 116: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación TAH para año de prueba.




Figure 117: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación TAH para año de prueba.




Figure 118: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación TAH para año de prueba.




Figure 119: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación TAH para año de prueba.




Figure 120: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación TAH para año de prueba.




Figure 121: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación TLA para año de prueba.




Figure 122: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación TLA para año de prueba.




Figure 123: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación TLA para año de prueba.




Figure 124: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación TLA para año de prueba.




Figure 125: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación TLA para año de prueba.




Figure 126: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación TLI para año de prueba.




Figure 127: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación TLI para año de prueba.




Figure 128: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación TLI para año de prueba.




Figure 129: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación TLI para año de prueba.




Figure 130: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación TLI para año de prueba.




Figure 131: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación UAX para año de prueba.




Figure 132: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación UAX para año de prueba.




Figure 133: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación UAX para año de prueba.




Figure 134: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación UAX para año de prueba.




Figure 135: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación UAX para año de prueba.




Figure 136: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación UIZ para año de prueba.




Figure 137: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación UIZ para año de prueba.




Figure 138: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación UIZ para año de prueba.




Figure 139: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación UIZ para año de prueba.




Figure 140: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación UIZ para año de prueba.




Figure 141: Gráfico de densidad hexagonal para pronóstico a 01 horas de la estación VIF para año de prueba.




Figure 142: Gráfico de densidad hexagonal para pronóstico a 06 horas de la estación VIF para año de prueba.




Figure 143: Gráfico de densidad hexagonal para pronóstico a 12 horas de la estación VIF para año de prueba.




Figure 144: Gráfico de densidad hexagonal para pronóstico a 18 horas de la estación VIF para año de prueba.




Figure 145: Gráfico de densidad hexagonal para pronóstico a 24 horas de la estación VIF para año de prueba.