

Redes neuronales para modelar y predecir la contaminación en entornos urbanos

Josefina Cardozo, Sergio Nesmachnow

Facultad de Ingeniería, Universidad de la República



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY

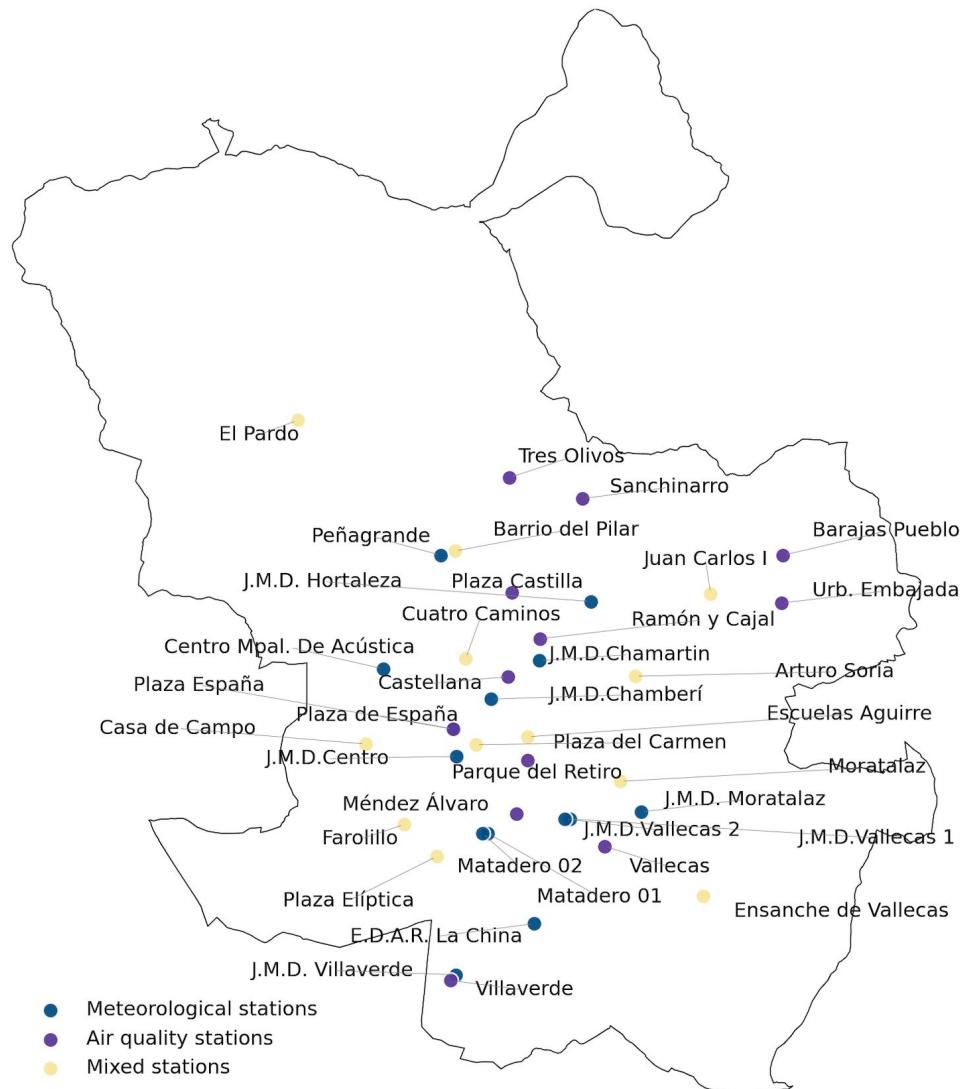
- La contaminación del aire es uno de los principales riesgos para la salud humana mundialmente
- **PM_{2.5}, NO₂ y O₃** causan miles de muertes prematuras cada año en Europa
- Predecir las concentraciones de contaminantes es clave para la prevención y para orientar las políticas públicas
- Los modelos estadísticos tradicionales (ARIMA, regresión) no logran capturar la dinámica no lineal y temporal



Caso de estudio

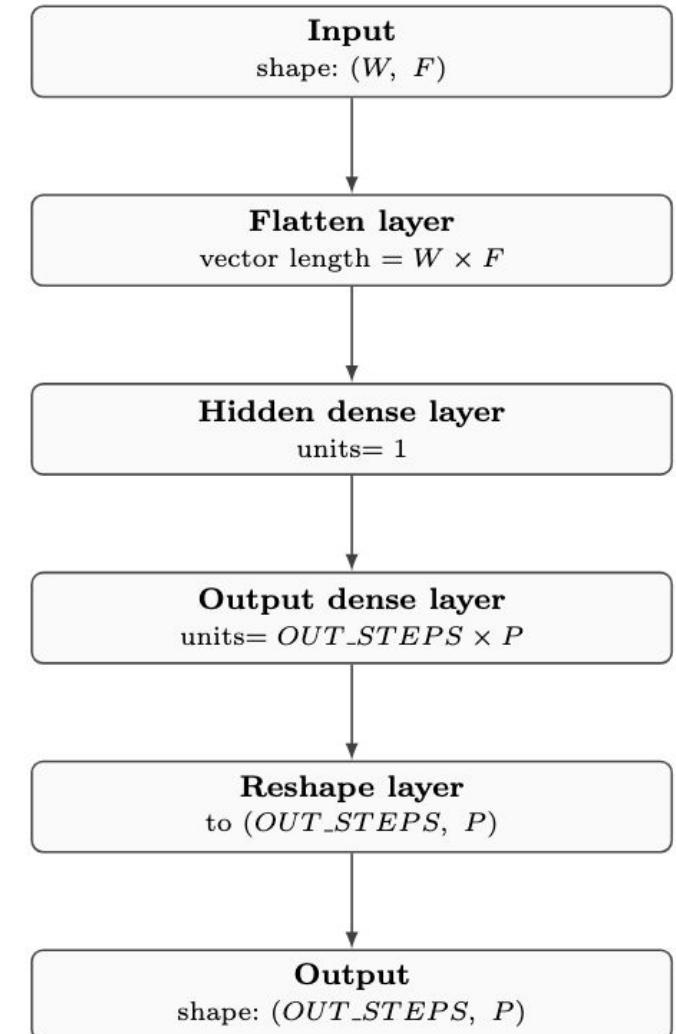


- Madrid, España — 37 estaciones de monitoreo (urbana tráfico, suburbana, urbana fondo)
- Observaciones **horarias** (Jul 2021 - Dic 2024) de datos.madrid.es
- Se excluyeron los períodos de confinamiento por COVID-19 para evitar dinámicas atípicas
- **Covariables meteorológicas:** temperatura, viento, radiación, precipitación, etc
- **Contaminantes:** PM_{2.5}, NO₂, O₃, PM₁₀, CO, SO₂



Implementación

- Utilizado como **modelo base** para la comparación con el LSTM
- Red neuronal feed-forward simple
- Optimizador Adam (tasa de aprendizaje 10^{-5})
- Función de pérdida: Error Absoluto Medio (MAE)
- Captura combinaciones no lineales de la entrada, pero **no tiene memoria temporal explícita**

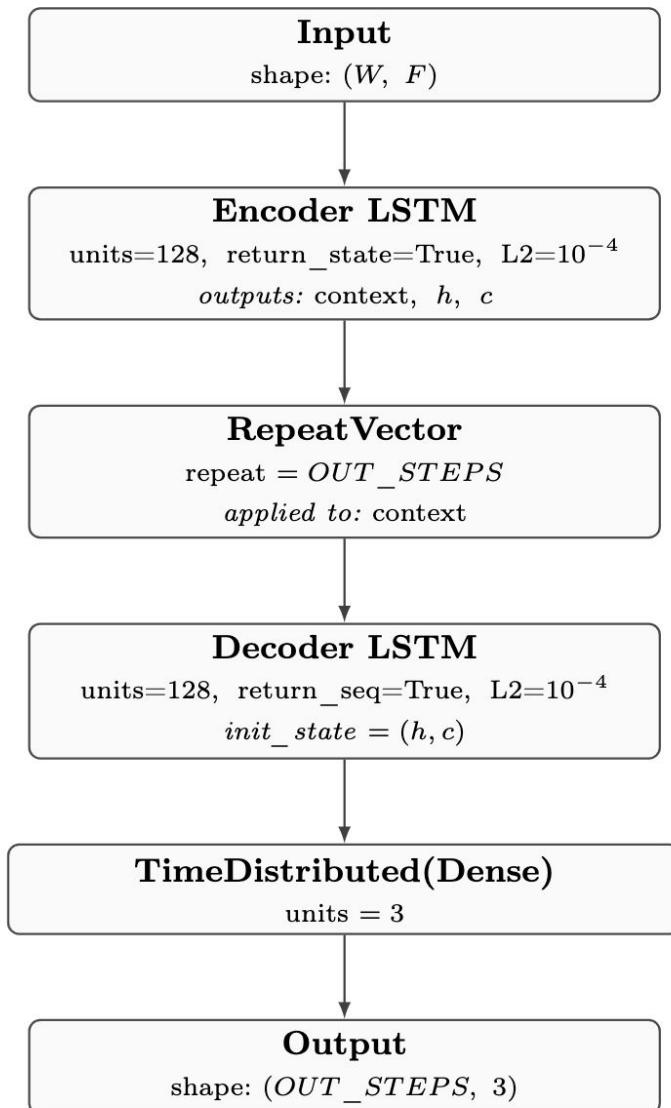


LSTM codificador-decodificador



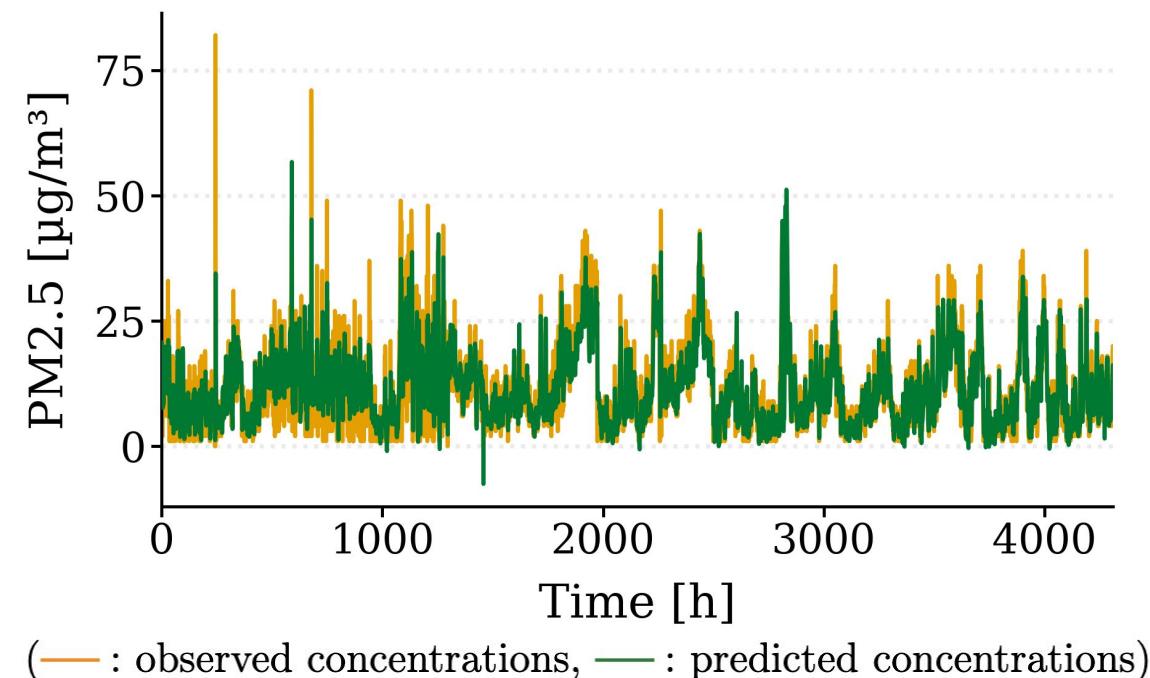
Implementación

- Arquitectura **Sequence-to-sequence**
- Codificador LSTM (128 unidades) que extrae las características temporales
- Decodificador LSTM (128 unidades) inicializado con los estados del codificador
- Regularización $L2 = 10^{-4}$ en codificador y decodificador
- El mismo optimizador (Adam, $lr = 10^{-5}$) y misma función de pérdida (MAE)
- Horizontes de predicción: 1 hora y 24 horas



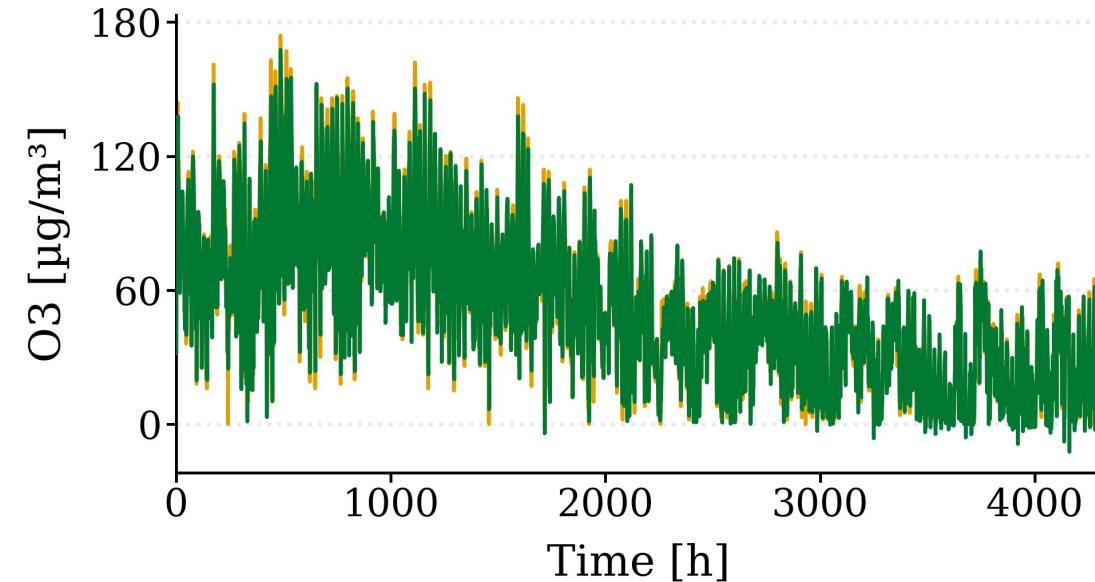
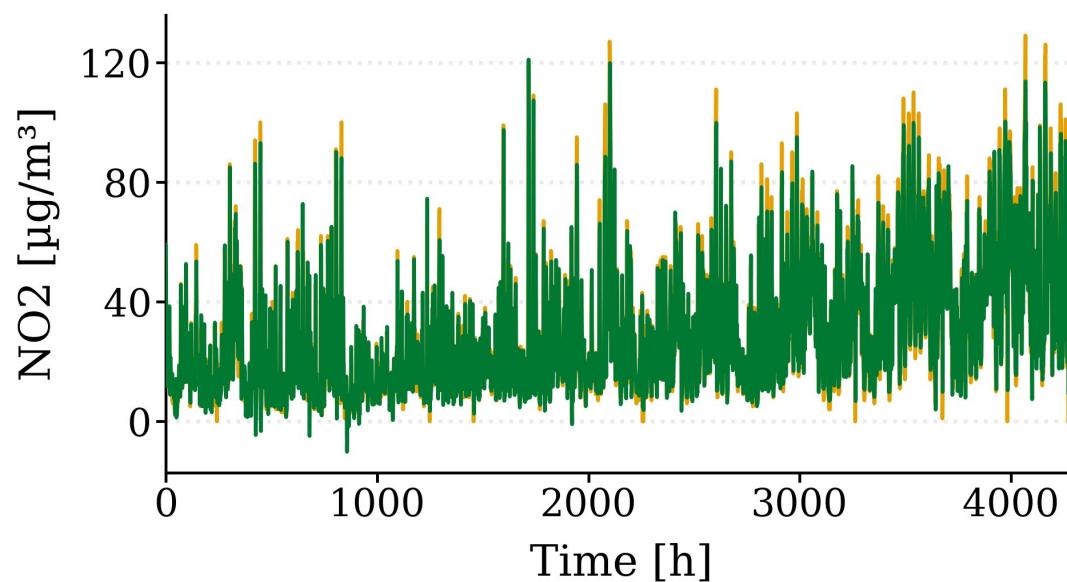
Resultados de predicción LSTM – PM_{2.5}

- Predicciones a una hora en la estación Escuelas Aguirre(urbana tráfico)
- Los picos abruptos y las fluctuaciones irregulares son más difíciles de modelar
- El modelo tiende a **suavizar los picos de contaminación**



Resultados de predicción LSTM – NO₂ y O₃

- El modelo LSTM codificador-decodificador sigue de cerca las tendencias
- NO₂ y O₃ muestran pronósticos más suaves y precisos
- El modelo captura de forma efectiva las dependencias temporales a corto plazo



(— : observed concentrations, — : predicted concentrations)

LSTM vs MLP comparación de desempeño

- Validación cruzada con tres particiones consecutivas
- El LSTM superó al MLP en los horizontes de 1 hora y 24 horas
- Reducciones de MAE entre **39–60 %** (1h) y **11–17 %** (24h)
- Evaluación por contaminante utilizando las métricas MAE y RMSE

<i>Horizon</i>	<i>Pollutant</i>	<i>MLP MAE</i>	<i>LSTM MAE</i>	<i>Improvement</i>
1h	PM _{2.5}	9.02	3.27	64%
1h	NO ₂	10.04	6.09	39%
1h	O ₃	16.34	6.39	61%
24h	PM _{2.5}	6.52	5.42	17%
24h	NO ₂	15.54	13.72	11%
24h	O ₃	18.44	15.97	13%

Conclusiones

- El modelo LSTM codificador–decodificador capturó eficazmente las dependencias temporales
- Modelar estas dependencias permite obtener pronósticos de calidad a corto plazo

Trabajo futuro

- Extender hacia un modelado espacio temporal incorporando interacciones entre todas las estaciones
- Actualmente desarrollando un modelo **GCN** combinado con el LSTM codificador-decodificador



Gracias por su atención



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY