

XL INTERNATIONAL CONFERENCE OF THE CHILEAN COMPUTER SCIENCE SOCIETY, SCCC 2021.

Universidad de La Serena, Facultad de Ingeniería, La Serena – Chile.

15 al 19 de Noviembre de 2021

A Deep Learning model for estimating parking space availability

María Pía Goicoechea - Julián Mastieri
Antonela Tommasel - Juan Manuel Rodriguez



Servicios de movilidad urbana

- ▶ Muchas ciudades y empresas cuentan con servicios digitales de información de movilidad urbana.
- ▶ Los servicios de movilidad urbana pueden presentar información como:
 - ▶ Congestión vehicular, cortes de calles/avenidas, demoras.
 - ▶ Ubicación en tiempo real de colectivos (autobuses), subterráneos, y otros medios de transporte público.
 - ▶ Monitoreo de disponibilidad de estacionamiento.
 - ▶ OBJETIVO: Predicción de disponibilidad de estacionamiento.
- ▶ Ejemplos: Buenos Aires ¿Cómo llego?, Tandil GPSSumo, Google Maps, Waze, ...

Motivación

- ▶ El transporte es uno de los servicios esenciales que debe prestar el estado.
- ▶ La disponibilidad de estacionamiento en las ciudades es uno de los principales problemas del transporte urbano.
- ▶ El proceso de búsqueda de estacionamiento conlleva:
 - ▶ Incremento del tiempo del uso del vehículo.
 - ▶ Incremento en el tráfico.
- ▶ En las grandes ciudades se han empezado a aplicar restricciones de circulación o estacionamiento para disminuir el problema.

Soluciones actuales

- ▶ Actualmente existen soluciones que permiten llevar control de estacionamiento a nivel de cada lugar.
- ▶ Algunas de estas soluciones requieren la instalación de sensores en cada uno de los lugares de estacionamiento disponible.
 - ▶ Adicionalmente requieren algún tipo de comunicación de los sensores con el servidor.
 - ▶ Si bien cada sensor puede no representar una gran inversión, la cantidad de sensores y su instalación puede resultar en una inversión significativa.
- ▶ Otras soluciones se basan en procesamiento de imágenes obtenidas mediante cámaras de seguridad.
 - ▶ Las cámaras son costosas.
 - ▶ Se requiere hardware para procesar gran cantidad de imágenes.



Caso de estudio: Tandil

Tandil es una ciudad en el centro de la provincia de Buenos Aires, Argentina:

- ▶ Población en 2010: 123.871
- ▶ Población estimada a 2015: 146.000
- ▶ 1452 vehículos nuevos registrados en 2019
- ▶ Cuenta con un sistema de estacionamiento medio en la zona céntrica conocido como Sistema Único de Movilidad Ordenada (SUMO)



SUMO

Tandil cuenta con 95 parquímetros instalados en las cuadras donde hay estacionamiento medido.

- ▶ Se operan a través de tarjetas especiales de proximidad.
- ▶ Cada usuario debe registrar sus vehículos a su tarjeta para poder estacionar.
- ▶ Al estacionar, el conductor debe marcar su entrada en el parquímetro más cercano.
- ▶ Al retirarse, el conductor debe marcar su salida en el parquímetro más cercano.



Representación de la problema

Características adicionales:

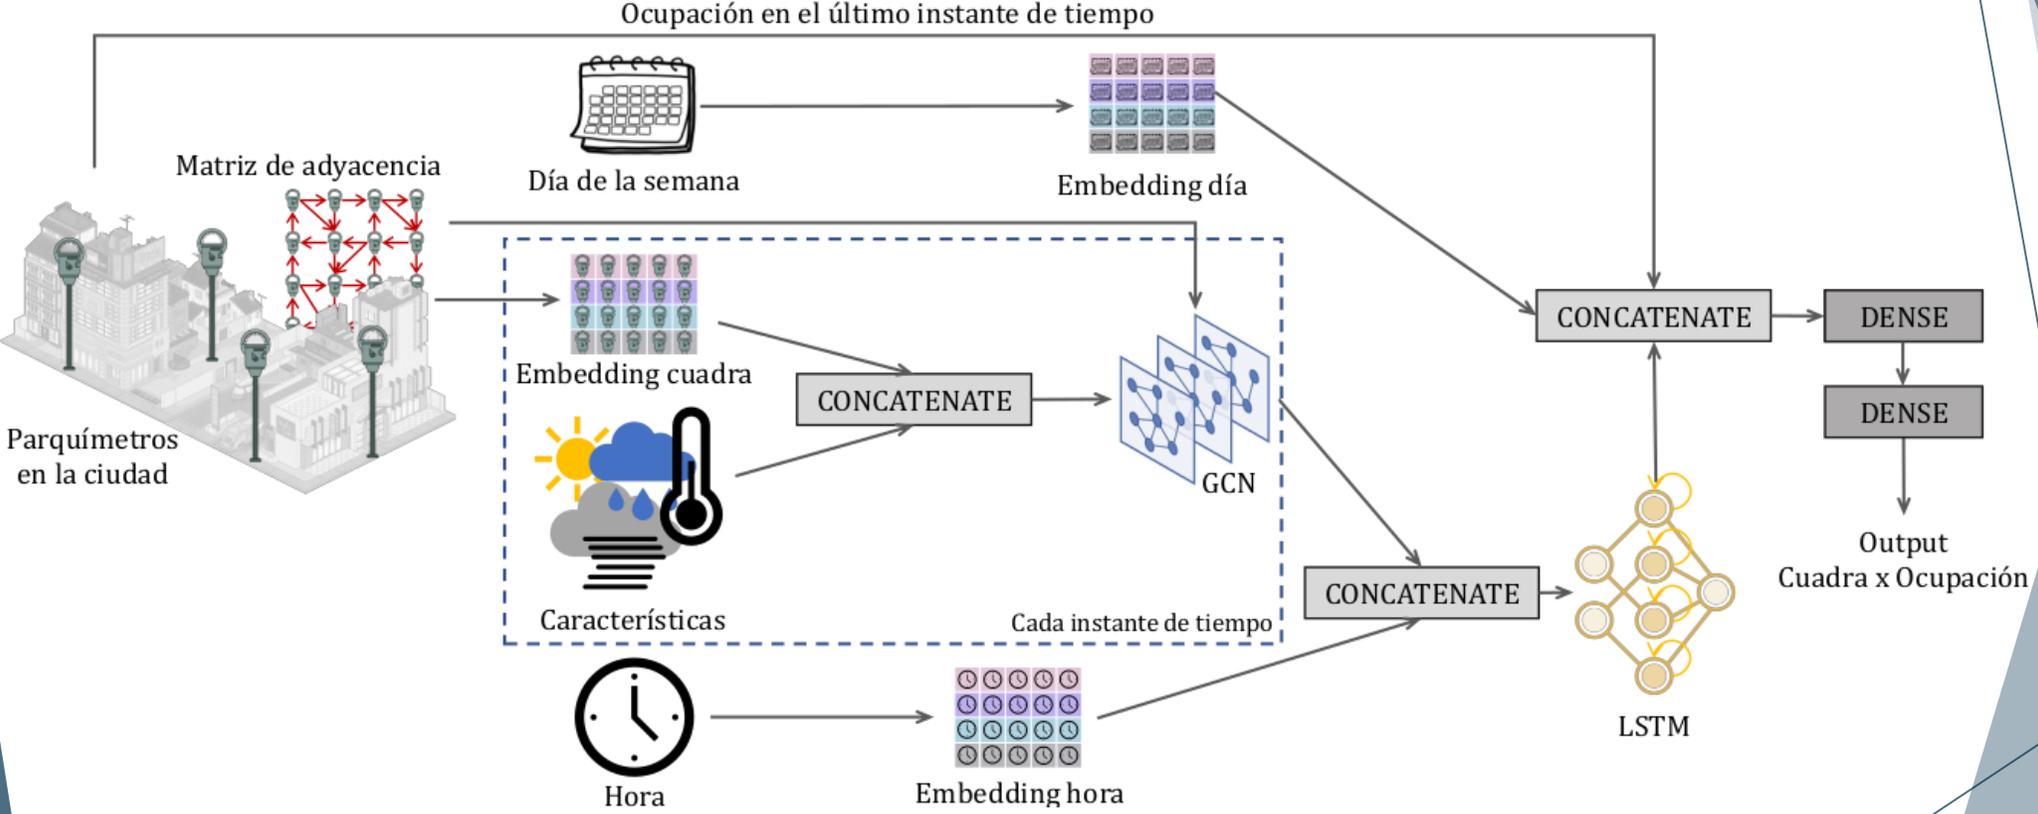
- ▶ Meteorológicas reportadas por el SMN:
 - ▶ Temperatura promedio (en grados centígrados).
 - ▶ Precipitaciones totales (en milímetros).
 - ▶ Velocidad media del viento (en kilómetros por hora).
 - ▶ Presencia o ausencia de lluvia.
 - ▶ Presencia o ausencia de tormenta.
 - ▶ Presencia o ausencia de niebla.
- ▶ Días de receso escolar.

Representación de la problema

Limitaciones de los datos:

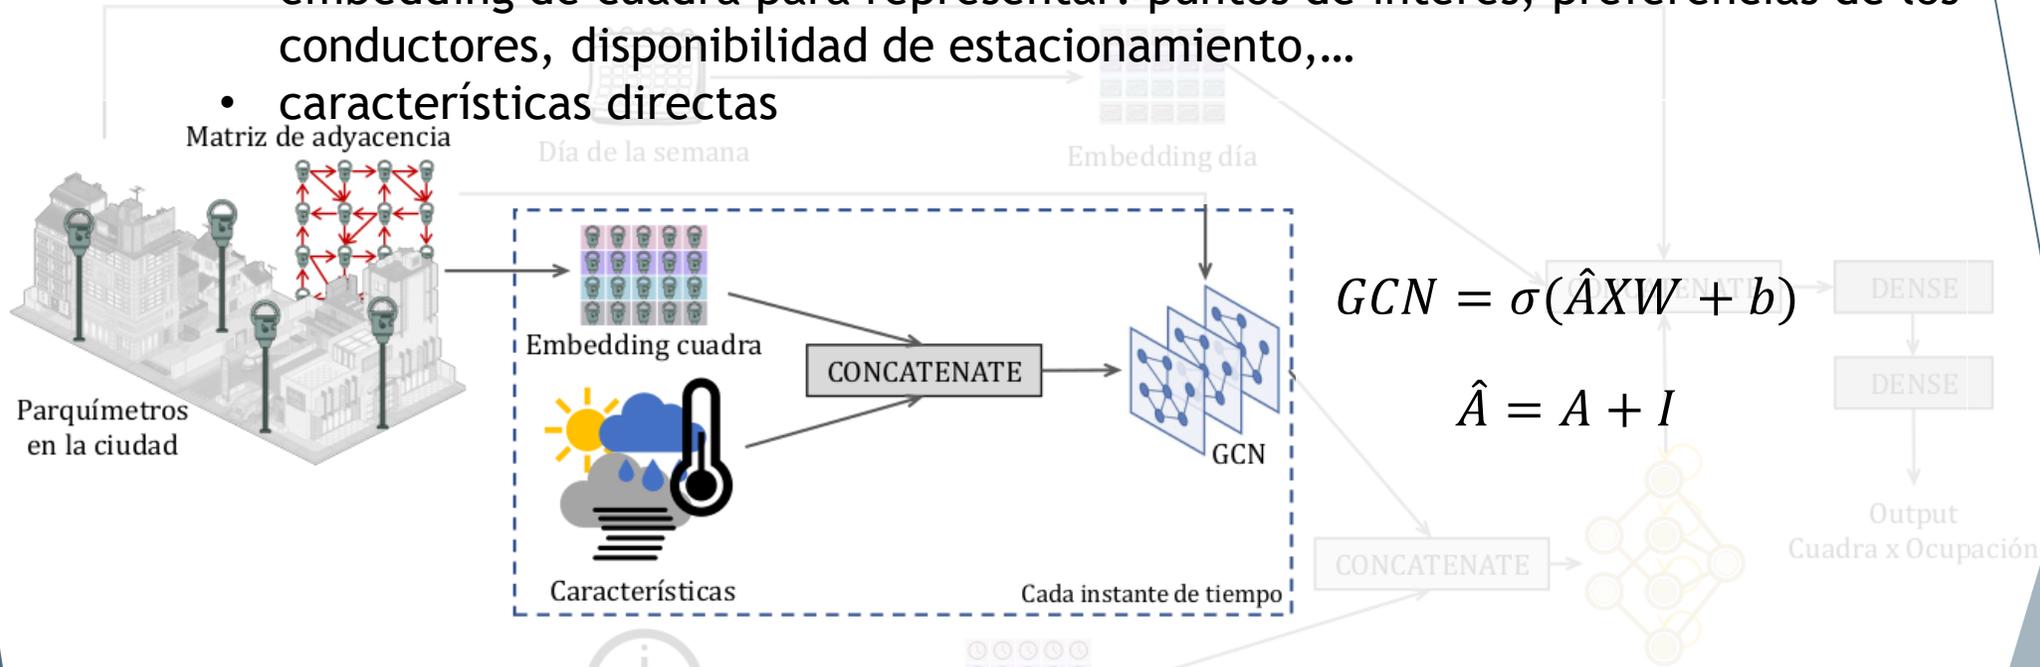
- ▶ Se contaba con datos históricos del 2019.
- ▶ Es estacionamiento medio funciona solo:
 - ▶ Lunes a viernes de 10:00 a 20:00.
 - ▶ Sábados de 10:00 a 14:00.
 - ▶ No hay estacionamiento medido durante los feriados.
- ▶ Variabilidad en el espacio disponible para estacionar por cuadra: Garages, lugares reservados, estacionamiento de una o dos manos.
- ▶ Los espacios de estacionamiento no se encuentran delimitados. Dependen del tamaño de los vehículos y espacios dejados entre vehículos.

Enfoque de estimación



Enfoque de estimación

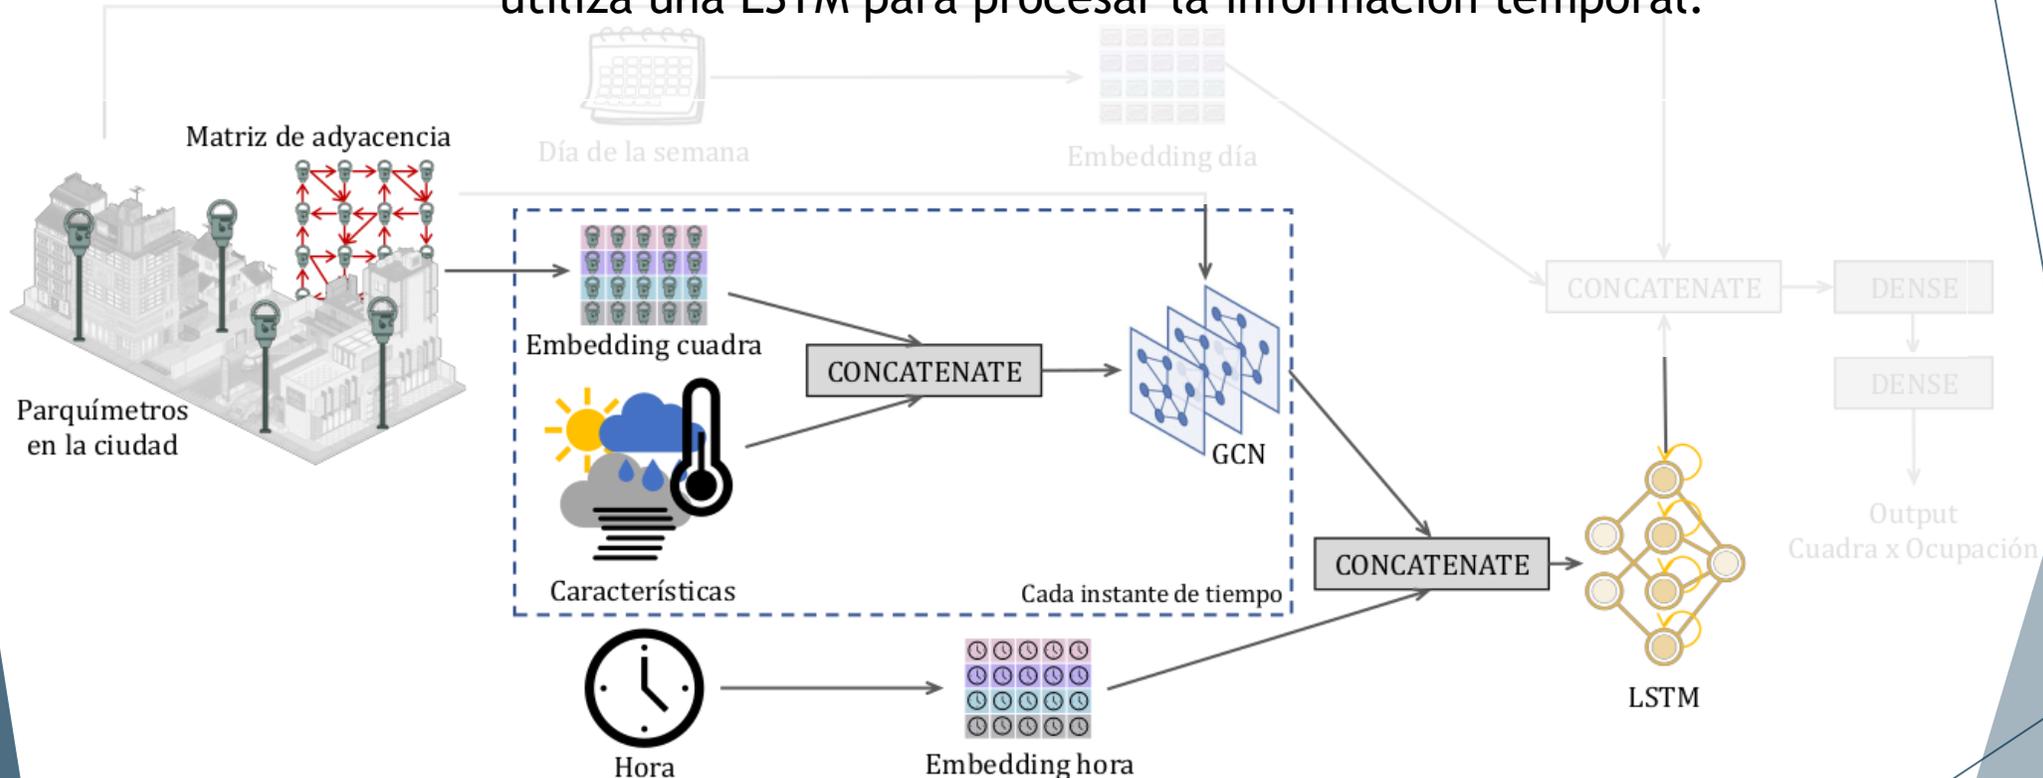
- Cada cuadra es representada por una combinación de:
 - embedding de cuadra para representar: puntos de interés, preferencias de los conductores, disponibilidad de estacionamiento,...
 - características directas



- La capa GNC distribuye características entre las cuadras cercanas. Esto se debe a que si un conductor no encuentra lugar en una cuadra, es posible que estacione en una cuadra cercana.

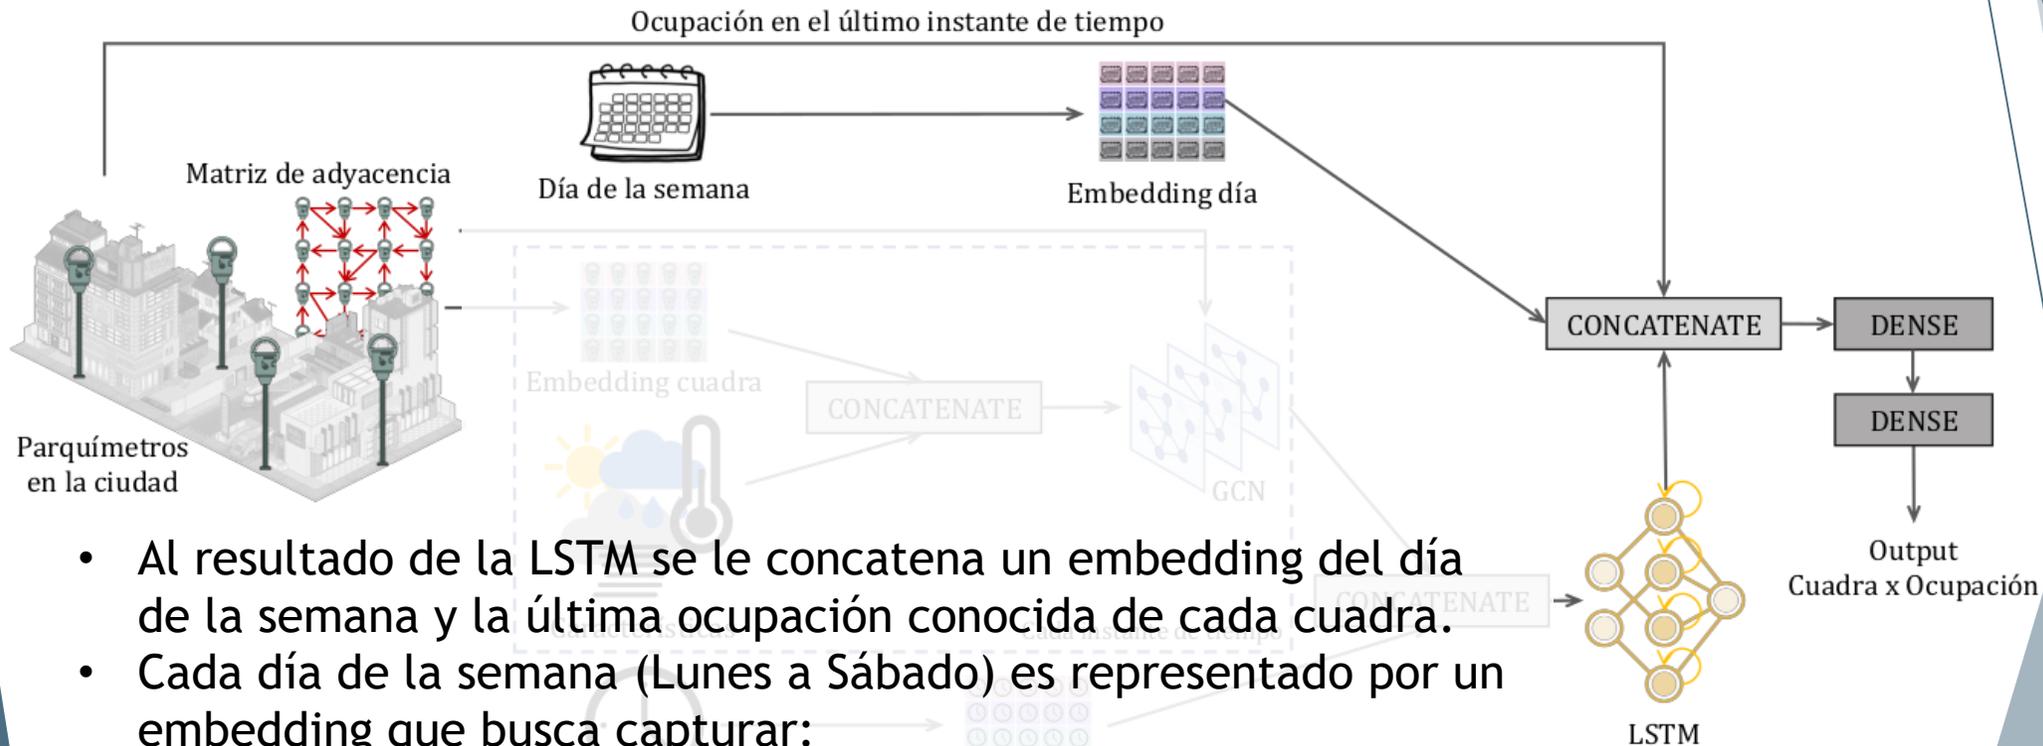
Enfoque de estimación

- Se adiciona información sobre la hora de cada ventana de tiempo. Se utiliza una LSTM para procesar la información temporal.



- Con el embedding de hora se espera capturar:
 - Apertura/cierre de negocios y punto de interés.
 - Entrada y salida de escuelas
 - Horarios bancarios.

Enfoque de estimación



- Al resultado de la LSTM se le concatena un embedding del día de la semana y la última ocupación conocida de cada cuadra.
- Cada día de la semana (Lunes a Sábado) es representado por un embedding que busca capturar:
 - Tipo de estacionamiento por cada día particular.
 - Tipo de puntos de interés más buscados por días de semana.
- La predicción final se realiza utilizando dos capas densas, y se genera un estimado de ocupación por cuadra.

Evaluación experimental

- ▶ Se evaluaron 64 configuraciones de los hiper-parámetros.
- ▶ Se evaluaron alimentar a la red con diferentes características.

Hiperparámetro	Valores
Neuronas red GCNN	10, 20
Tamaño embedding cuadra	5, 10
Tamaño embedding hora	5, 10
Tamaño embedding dia	5, 7
Neuronas de la red LSTM	20, 30
Neuronas de la capa densa	10, 20

Características	MAE	MSE
Base	1,221	2,9245
Actas de infracción	1,2059	2,8589
Tiempo estacionado	0,9331	0,6034
% de ocupación	1,199	2,8281
Tiempo estacionado, actas de infracción	<u>0,9213</u>	1,6
Actas de infracción, % de ocupación	1,1947	2,8699
Tiempo estacionado, % de ocupación	0,9187	1,6552
Tiempo estacionado, actas de infracción, % de ocupación	0,9389	<u>1,578</u>

Evaluación experimental

- ▶ Sobre le mejor modelo se evaluó:
 - ▶ Variar el tamaño de las ventanas de tiempo.
 - ▶ Variar la cantidad de instancias hacia el pasado utilizadas para hacer la predicción.

Tiempo	MAE	MSE
3 minutos	0,9187	1,6552
5 minutos	0,6058	0,5757
10 minutos	<u>0,7232</u>	<u>0,604</u>
20 minutos	0,8317	1,2774

Pasado	MAE	MSE
3 instancias	<u>0,6058</u>	<u>0,5757</u>
4 instancias	0,6366	0,5908
5 instancias	0,5993	0,5724
6 instancias	0,5981	0,5637

Evaluación experimental

Características Externas	MAE	MSE
Base & Tiempo estacionado, % de ocupación	0,5993	0,5724
Estado metereológico	<u>0,5885</u>	<u>0,5521</u>
Receso escolar	<u>0,5860</u>	0,5463
Receso escolar, estado metereológico	0,6071	0,5666
Temperatura	0,5955	0,5703
Temperatura, precipitaciones	0,6037	0,564
Temperatura, lluvia	0,6	0,5644
Receso escolar, temperatura	0,6008	0,5675
Receso escolar, lluvia	<u>0,5883</u>	0,545
Receso escolar, precipitaciones	0,5958	0,5611
Receso escolar, viento	0,5057	0,568
Receso escolar, tormenta	0,5992	0,562
Receso escolar, niebla	0,6075	0,6075

Evaluación experimental

Comparación contra otras técnicas:

- ▶ En todo los casos se utilizaron las mismas características e intervalos de tiempo.
- ▶ Yang et al. Utiliza ciertas características no disponibles, que fueron omitidas en el entrenamiento del modelo.

Comparación	MAE	MSE
Modelo propuesto	0,5885	0,5521
Yang et al.	2,4812	11,6655
Bagging con SVM	2,6390	14,5138
VAR	<u>1,7197</u>	<u>5,6714</u>

Conclusiones

- ▶ Se propone un modelo para la estimación de la ocupación de estacionamiento basado en redes GCNN y LSTM.
- ▶ Se evaluó en el contexto de la ciudad de Tandil, Argentina
- ▶ Se comprobó, para este escenario, el modelo desarrollado mejora los resultados de otras técnicas de la literatura.
- ▶ La inclusión de variables externas (como el clima) mejoró la calidad de las predicciones.
- ▶ No requiere una inversión extra que si requeriría la instalación de sensores.
- ▶ Este estudio se llevó a cabo en una ciudad de tamaño intermedio, mientras otros estudios se ha llevado a cabo en ciudades más grandes.

¡Muchas gracias por su atención!

¿Preguntas?

