

A Deep Learning model for estimating parking space availability

María Pía Goicoechea*, Julián Mastieri*, Antonela Tommasel[†] and Juan Manuel Rodríguez[†]

*Facultad de Ciencias Exactas, UNICEN

Email: {mgoicoechea, jmastieri}@alumnos.exa.unicen.edu.ar

[†]ISISTAN, CONICET-UNICEN

Email: {antonela.tommasel, juanmanuel.rodriguez}@isistan.unicen.edu.ar

Abstract—Finding a free space to park has become one of the main problems for drivers and urban mobility. Traffic congestion, usually caused by drivers looking for a free parking space, can increase energy consumption and air pollution. In this context, providing information regarding the availability of parking spots is crucial to help drivers find a free parking space faster, thus reducing parking search traffic. This paper proposes an approach based on GCNN and an LSTM model to forecast real-time future parking availability by capturing both the temporal occupancy patterns and the geospatial interactions in traffic flow. Different model configurations were evaluated by varying the information fed to the model (e.g., weather forecast, parking violations), the extent of historical data used, and the forecasting period. Experimental evaluation over historical parking data of the city of Tandil in Argentina showed that the proposed approach was able to outperform other state-of-the-art models significantly.

Index Terms—parking, smart mobility, deep learning, smart cities

I. INTRODUCCIÓN

El transporte público es uno de los servicios esenciales que las ciudades deben proveer a sus ciudadanos. Con el advenimiento de las tecnologías de posicionamiento, se comenzó a estudiar cómo utilizarlas para la estimación en tiempo real del estado del transporte público en las ciudades (por ejemplo, *BA Cómo Llego*¹ en la Ciudad Autónoma de Buenos Aires en Argentina, o *GPSSumo*² en Tandil, también en Argentina) para informar a los ciudadanos la ubicación de los colectivos y permitir estimar su tiempo de arribo. En años recientes, han surgido estudios aprovechando el uso masivo de los *smart-phones*, sus tecnologías de posicionamiento y conectividad.

La disponibilidad limitada de estacionamiento en la calle y su congestión de tráfico asociada se han convertido en algunos de los principales problemas de los sistemas de transporte urbano [1]. En los últimos años se han comenzado a implementar políticas para la regulación del tránsito y estacionamiento. Sin embargo, para implementarlas es necesario contar con datos sobre la utilización de los espacios. La falta de fuentes confiables que informen sobre la ocupación del estacionamiento, tanto actual como pronosticada, es un contratiempo para la obtención de información y estadísticas acerca del sistema

de tráfico vehicular actual. La mayor parte de las soluciones propuestas en la actualidad se centran en informar sobre el estado actual del estacionamiento. Sin embargo esto no permite a los conductores planificar con anticipación donde estacionar. En este sentido, resulta de mayor utilidad proveer la información sobre el posible estado de ocupación en el futuro, lo que permitiría planificar los viajes con mayor antelación [2].

Además de los beneficios para los conductores, la estimación o predicción del nivel de ocupación de estacionamiento es útil en la gestión y planificación del transporte. La información obtenida podría ser utilizada para la elaboración de políticas públicas, con el fin de reducir el número de vehículos estacionados que no abonan la tarifa de estacionamiento. A través de una predicción confiable de la demanda, las autoridades también podrían ajustar la tarifa dinámicamente para mejorar la eficiencia general de los recursos de estacionamiento en la calle, así como planificar el horario de los inspectores de tránsito para que verifiquen el cumplimiento.

Considerando las diversas problemáticas mencionadas anteriormente relacionadas a sistemas de estacionamiento, este trabajo tiene como objetivo principal estimar el nivel de ocupación de estacionamiento como intermediario para determinar qué lugares tienen una mayor probabilidad de encontrarse disponibles. En este sentido, al brindar información sobre el tráfico en la ciudad y el uso y disponibilidad de espacios de estacionamiento, este trabajo pretende ser de utilidad y relevancia para las ciudades, municipios y ciudadanos.

II. TRABAJOS RELACIONADOS

En el contexto movilidad inteligente, se han propuesto soluciones para lograr un mejor uso de los espacios disponibles y controlar los efectos negativos que se generan en la búsqueda de estacionamiento. En este sentido, diversos trabajos han estudiado la posibilidad de predecir o estimar la disponibilidad de espacios de estacionamiento. Estos trabajos difieren respecto al modelo empleado, al origen de los datos que utilizan, la granularidad de las predicciones (por ejemplo, si es a nivel de cuadra, bloque de cuadras o playa de estacionamiento) y el horizonte (o tiempo a futuro) de las predicciones.

Gran parte de los trabajos en la literatura han basado su estimación en modelos de redes neuronales. Por ejemplo, Ji et al. [3] utilizaron una *Wavelet Neural Network* con información histórica de los dos o tres días anteriores a la predicción, o

M.P.G. y J.M. contribuyeron de forma equitativa a este trabajo

¹<https://mapa.buenosaires.gob.ar/comollego>

²<http://www.gpssumo.com/>

solo el día anterior y los mismos días de semanas previas en el caso de predecir para el fin de semana. Los autores realizaron esta distinción considerando que los fines de semana no tienen patrones similares a los de los días de semana, pero sí patrones similares entre ellos. Vlahogianni et al. [4] no generaron modelos distintos de acuerdo al tipo de día, pero si incluyeron dicho tipo en su modelo basado en *Recurrent Neural Networks*. Este modelo fue combinado con un análisis de supervivencia para determinar la probabilidad de que un espacio se libere en los siguientes intervalos de tiempo.

Chen [5] desarrolló su mejor modelo predictivo a partir de una *Feed-Forward Neural Network*. Dicho modelo consideró ocupaciones promedio por hora e incluyó información respecto a eventos. La mayor tasa de error se observó para las regiones cercanas al centro de la ciudad, las cuales presentan una mayor frecuencia de entrada y salida, generando más incertidumbre para la predicción. Por el contrario, de acuerdo con Yang et al. [6], la predicción de disponibilidad de estacionamiento puede ser más sencilla en los distritos comerciales centrales que en las zonas externas recreativas debido a la existencia de patrones de actividades recurrentes. Yang et al. [6] propusieron un modelo combinado de *Graph Convolutional Neural Network* (para modelar la información espacial) y *Long Short Term Memory* (para modelar la información temporal), y analizaron la inclusión de diversas características referidas al clima y velocidad del tráfico.

Además de redes neuronales, otros trabajos exploraron el uso de técnicas tradicionales de regresión o clasificación [7, 8, 9]. Zheng et al. [7] propusieron modelos basados en *regression tree*, *support vector regression* y redes neuronales. Los mejores resultados se obtuvieron combinando características referidas al día y hora de la semana con observaciones anteriores, y utilizando los modelos tradicionales. Fabusuyi et al. [8] exploraron métodos tradicionales de clasificación binaria para determinar la disponibilidad o no de espacios. Al igual que en [5, 6] incluyeron información sobre el día de la semana, clima y eventos. Al igual que en [3], Zhao y Zhang [9] incluyeron información diferenciada de acuerdo a si la predicción era para un día laboral o fin de semana. Para esto, utilizaron cuatro modelos: *logistic regression*, *ARIMA*, *support vector machine* y redes neuronales. Los mejores resultados fueron obtenidos utilizando los modelos tradicionales de clasificación.

Si bien la mayoría de los trabajos existentes tiene en cuenta datos históricos [3, 5, 6, 7, 9, 10], otros trabajos se centraron en la utilización de datos provenientes de sensores instalados en las calles de la ciudad, tanto en tiempo real [4], como históricos [7]. Por su parte, Fabusuyi et al. [8] utilizó una combinación de datos en tiempo real con datos históricos de ocupación y calendarios de eventos.

En lo que respecta a la granularidad, los trabajos relevados analizan tres niveles de predicción: cuadras individuales [7], bloques de cuadras [4, 6], playas de estacionamiento [3, 9] y combinaciones de ellos [10]. En relación a bloques de cuadras, se presentaron diferentes criterios para su agrupamiento. Por ejemplo, Yang et al. [6] propusieron una subdivisión basada en las conexiones formadas por las calles y los lugares para

estacionar en 39 bloques, mientras que Vlahogianni et al. [4] segmentaron la zona cubierta por sensores en 4 en función de los recorridos que pueden realizar los conductores al buscar espacios disponibles. Por su parte, Chen [5] consideró bloques de entre 100 y 120 espacios de almacenamiento, lo que equivale a entre 6 o 8 cuadras juntas. Si bien las cuadras individuales permiten una localización más exacta de los espacios disponibles, Chen [5] sostiene que podría ser más útil la predicción por zonas dado que los conductores generalmente quieren estacionar dentro de un cierto radio de proximidad.

El horizonte de la predicción, en la mayoría de los trabajos analizados se centra en el corto plazo, por ejemplo, con intervalos de media a una hora [4, 5, 6]. Por el contrario, Fabusuyi et al. [8] y Zheng et al. [7] se enfocaron en predicciones con horas o días de anticipación. Tanto Vlahogianni et al. [4] como Zheng et al. [7] concluyeron que los errores aumentan a medida que se incrementa el horizonte de las predicciones.

En resumen, del análisis realizado surge que los trabajos existentes no consideran aspectos relacionados a: i) cómo afectan a la estimación la consideración de distintos intervalos de tiempo de entrenamiento a las predicciones, y ii) la inclusión de datos externos, como el clima. Por otra parte, varios de los estudios dependen de infraestructura y hardware especializados que puede no encontrarse siempre disponible.

III. ESTIMACIÓN DE NIVEL DE OCUPACIÓN DE ESTACIONAMIENTO

El presente trabajo se centra en la ciudad de Tandil, ubicada en el centro-este de la provincia de Buenos Aires en Argentina. En 2015, la municipalidad colocó 95 parquímetros en el área céntrica de la ciudad. Dichos parquímetros, ubicados uno por cuadra en el área de estacionamiento medido, permiten el registro del inicio y finalización del período de estacionamiento utilizando una tarjeta asociada a las matrículas de los vehículos a estacionar. Los parquímetros resultan una alternativa de menor costo a los sensores [4, 5, 7] que permite cubrir una mayor área de estacionamiento y realizar un muestro filedigno sobre diferentes calles de la ciudad, desde las más céntricas, con mayor flujo de tránsito, hasta las más alejadas.

Como se ha mencionado previamente, el objetivo es estimar el nivel de ocupación para una cuadra dada en un momento del día dado. Para conseguir dicho objetivo, se presenta un modelo de aprendizaje profundo que integra las relaciones espaciales derivadas de la organización espacial del sistema de estacionamiento (modeladas con un red neuronal basada en una GCNN, *Graph Convolutional Neural Network*) y la evolución temporal diaria de la ocupación (modeladas con una red neuronal recurrente LSTM, *Long Short-term Memory*). Tomando como base los dos tipos de redes, la Fig. 1 presenta el modelo definido, el cual recibe como entrada el día de la semana, las características para cada cuadra en las N ventanas de tiempo pasadas, y la hora del día para las N ventanas de tiempo pasadas.

Cuando la red procesa las ventanas de tiempo anteriores para las cuadras, en primer lugar aplica la misma GCNN para

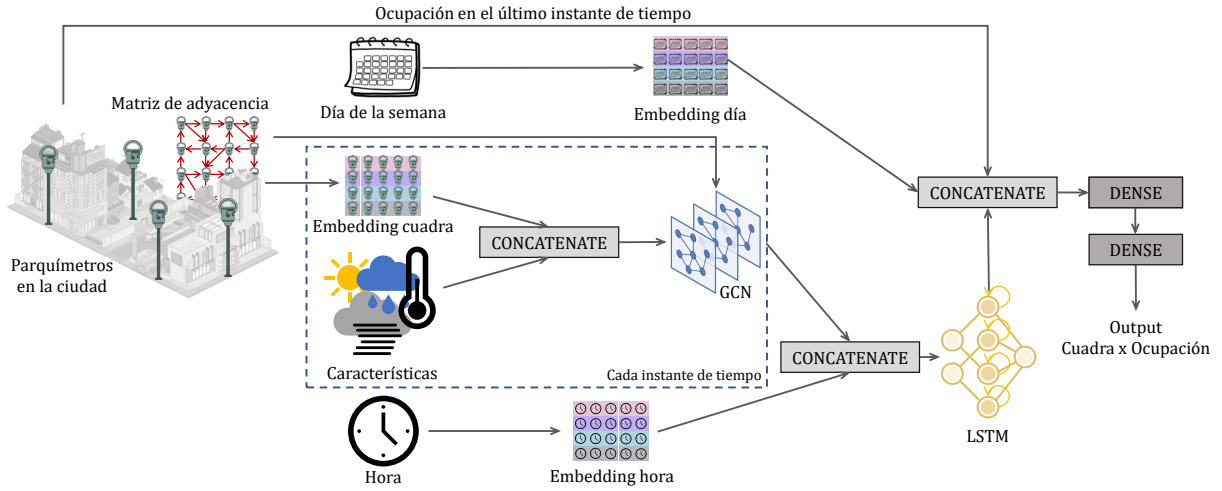


Fig. 1: Descripción de la arquitectura del modelo utilizado

cada paso de tiempo, la cual se basa en el trabajo de Kipf y Welling [11] y se define como:

$$GCNN = \sigma(\hat{A}XW + b) \quad (1)$$

Donde $\hat{A} = A + I$, A es la matriz de adyacencia, X es la representación de las cuadras, y σ es la función de activación ReLU. El grafo base fue definido a partir de la ubicación de los parquímetros en las calles de la ciudad (uno por cuadra), donde cada parquímetro (o cuadra) es representado por un nodo y las conexiones entre ellos como arcos dirigidos, como puede observarse en la Fig. 2. Se consideró que un parquímetro j se encuentra conectado con el parquímetro i , es decir $A_{ij} = 1$, si desde j es posible llegar a i respetando el sentido de circulación de las calles, sin pasar por ningún otro parquímetro en el camino. Esta consideración responde a que si un conductor desea estacionar su vehículo en la cuadra donde se encuentra el parquímetro j , pero no encuentra lugar, es probable que conduzca hasta i , ya que se ubica a una distancia peatonal razonable y no requiere conducir por calles extras. Por ejemplo, en la Fig. 2b se puede observar una parte del grafo creado para representar las conexiones entre los parquímetros. Si un conductor desea estacionar en la cuadra 69 pero no hay espacios disponibles, es probable que estacione en las cuadras 62 o 68 pero no en las 63, 77, 70 o 76 ya que, si bien estos se encuentran a la misma distancia caminando, requieren de una mayor circulación en el vehículo.

A su vez, para cada uno de los pasos de tiempo, se tiene el identificador de la cuadra y un conjunto de características (por ejemplo, cantidad de ingresos, cantidad de egresos, tiempo de ocupación, estado meteorológico, entre otras posibilidades). El identificador es una variable categórica que es utilizada para obtener las características latentes de cada cuadra representada por vectores de *embeddings* entrenables. Luego, X resulta de la concatenación de estos dos elementos. Finalmente, como resultado de la GCNN se obtiene una representación de $Cuadras \times Ventanas\ de\ tiempo \times Unidades\ de\ la\ GCNN$, donde la representación de cada cuadra resulta de una combinación lineal de sus características y aquellas de las cuadras adyacentes, es decir cuadras de donde pueden venir vehículos.

Luego, a la representación de las cuadras se le concatena la representación de las horas. Dicha representación consiste en un vector de características latentes obtenido a partir de una capa de *embeddings*. Como resultado, se obtiene una representación de $Ventanas\ de\ tiempo \times Embedding\ de\ horas$, la cual es replicada $Cuadras$ veces, y es finalmente concatenada con la representación de las cuadras para ser procesadas utilizando una capa recurrente LSTM, de la cual se extrae la última salida. En este punto, cada cuadra es tratada como un elemento distinto, ya que las relaciones entre las cuadras son consideradas por la capa GCNN.

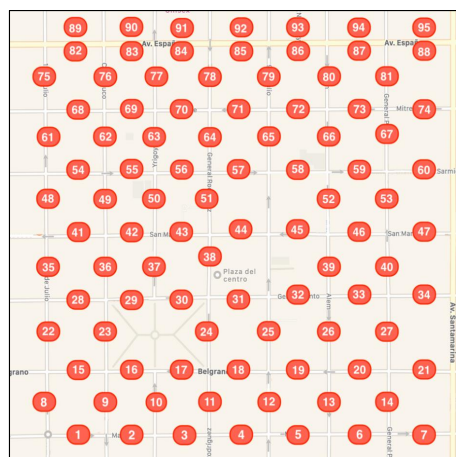
Finalmente, para obtener la estimación de la ocupación, se concatenan la representación de los días, la salida de la capa LSTM y la última ocupación de la cuadra (extraída directamente de la entrada de la red). La representación de los días de la semana es obtenidas a partir de una capa de *embeddings* que extrae las características latentes del día de la semana. A su vez, la inclusión de la última ocupación conocida tiene como objetivo facilitar el cálculo de la estimación ya que la nueva ocupación será una variación de la ocupación actual. Estas entradas son procesadas por dos capas densas, cuya salida es la estimación del nivel de ocupación.

IV. EVALUACIÓN EXPERIMENTAL


Para evaluar la performance del modelo propuesto, se llevó a cabo una evaluación experimental con el objeto de responder a las siguientes preguntas de investigación:

- **PI1.** El modelo propuesto admite diversas variantes respecto a las características que se incluyen (tanto internas como externas), la longitud de los intervalos de análisis y el historial a considerar. ¿Cómo las diferentes configuraciones del modelo afectan las estimaciones realizadas?
- **PI2.** Una vez seleccionada la mejor configuración del modelo, ¿Cómo comparan las estimaciones del modelo propuesto con aquellas de otros modelos en la literatura?

Para esto, describimos los datos utilizados, el proceso de extracción de características, los detalles de implementación y los trabajos para usar de base en la comparación.



(a) Distribución de los parquímetros en la zona céntrica de la ciudad



(b) Esquema de una porción del grafo utilizado en el modelo

Fig. 2: Derivación del grafo a partir de la ubicación de los parquímetros de la ciudad

A. Datos utilizados en el estudio

El presente trabajo se centra en el sistema de parquímetros de la ciudad de Tandil. Según el último censo realizado en 2010, Tandil cuenta con un total de 123.871 habitantes y se estima que en 2025 se alcanzarán aproximadamente los 146.000 habitantes³. Esta ciudad cuenta con gran cantidad de automotores circulando diariamente por sus calles. Como referencia, según datos oficiales en 2019, se registraron 1452 nuevos vehículos⁴.

Se contó con los datos históricos de los 95 parquímetros para el año 2019⁵, los cuales fueron provistos por el gobierno municipal. Para cada día, se tienen tres categorías de datos: detalles, estadísticas e infracciones. Los *detalles* incluyen características asociadas a las entradas y salidas de vehículos del estacionamiento tales como el ID del parquímetro, la dirección y cuadra en la que se encuentra ubicado, geolocalización (latitud y longitud), el horario y tipo de operación realizada (ingreso o salida). En el caso de operaciones de salida, también se incluyen el tiempo total de estacionamiento y su importe. Las *estadísticas* proveen características referidas a las recargas de saldo en las tarjetas. Finalmente, *infracciones* provee información de las actas de infracción emitidas incluyendo fecha, matrícula del vehículo infraccionado, ubicación y su estado acta (paga, impaga o anulada). Para el propósito de este trabajo, la categoría *estadísticas* fue descartada del análisis.

El sistema de estacionamiento medido solo funciona durante los días hábiles (lunes a sábado), con lo que los domingos y feriados fueron descartados por no poseer datos. Los datos restantes fueron separados en meses y, dentro de cada mes, en días de semana y fin de semana. Esto ayudó a localizar registros asociados a un determinado evento ya que, por

ejemplo, los comercios ubicados en la zona de estacionamiento medido presentan distintos horarios de apertura y cierre los fines de semana que los días de semana. Incluso el sistema de estacionamiento medido cuenta con distintos horarios, comenzando todos los días a las 10 horas y finalizando los días de semana a las 20 horas y los sábados a las 14 horas.

Un análisis exploratorio de los datos mostró diferencias de distribución de ocupación de las plazas de estacionamiento de acuerdo al día y hora. Por ejemplo, mientras que la mayor tasa de ocupación para los lunes se observó durante el horario de la tarde, para los viernes fue al mediodía. En lo que respecta a la distribución espacial de la ocupación, se observó que la mayor cantidad de espacios ocupados se concentró principalmente en las calles más céntricas, donde se encuentra la mayor densidad de establecimientos comerciales.

Además de los datos históricos de los parquímetros, se recolectaron distintos datos complementarios relacionados con el clima y los días asociados a los recesos escolares. Las fechas de los recesos fueron obtenidas del Calendario Escolar oficial de 2019⁶. Por su parte, los datos históricos diarios del estado meteorológico fueron obtenidos del Servicio Meteorológico Nacional⁷ e incluyeron:

- 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.

Evaluaciones preliminares mostraron la existencia de diferencias significativas entre las distribuciones de vehículos estacionados para días comprendidos o no en períodos de receso escolar, y días afectados o no por diversos fenómenos meteorológicos. Por ejemplo, se observó que en los días con

³Proyecciones de población por Municipio provincia de Buenos Aires 2010-2025. http://www.estadistica.ec.gba.gov.ar/dpe-4images/Proyecciones_x_municipio_2010-2025.pdf

⁴Registros Seccionales de la Propiedad del Automotor. <https://datos.gob.ar/dataset/justicia-inscripciones-iniciales-autos>

⁵Los datos anónimos y procesados se encuentran disponibles a pedido.

⁶<http://abc.gob.ar/secundaria/calendario-escolar-2019>

⁷Los datos se obtuvieron principalmente de <https://www.smn.gob.ar/descarga-de-datos> y se complementaron con datos extraídos de <https://tutiempo.net>

presencia de lluvia el flujo de vehículos estacionados era menor que en días soleados. En este contexto, se infiere que estos tipos de características podrían impactar de forma positiva en la estimación de ocupación.

B. Definición de las características a utilizar

A partir de los datos obtenidos se definieron diversas características para crear la representación diaria de cada cuadra. En primer lugar, se consideraron la cantidad de ingresos, egresos, tiempo total de estacionamiento (en minutos), flujo de vehículos (cantidad total de vehículos estacionados), el porcentaje de ocupación de cada cuadra y la cantidad de actas de infracción emitidas por cuadra. A estas, se agregaron características referidas a si el día se encuentra comprendido o no en un período de receso escolar, y las características referidas al estado meteorológico.

Para calcular la cantidad de ingresos y egresos, se consideraron aquellos registros que se encontrasen dentro del horario de funcionamiento del sistema. Complementariamente, con el objetivo de evitar tener cantidades de vehículos negativas por egresos de vehículos sin sus correspondientes ingresos, se analizaron los registros de datos desde las 0 hasta las 10 horas para calcular la cantidad de vehículos previamente estacionados al comienzo del horario de cobro. Esta situación puede darse debido a conductores que olvidaron registrar su salida del estacionamiento, o que arribaron al centro comercial antes del horario de inicio y registran su entrada ya que no se retirarán antes del mismo.

C. Trabajos de base para la comparación

Para la comparación con otros trabajos, se consideraron modelos tradicionales de regresión y estimación de series de tiempo, y el modelo definido por Yang et al. [6]. Este último fue elegido por ser similar al desarrollado en este trabajo, incorporando a la definición *multi-layer feed-forward decoders* para captar correlaciones no lineales entre los datos de entrada y filtrar la información redundante. Para este modelo, se siguió la implementación y parametrización original, debiendo ajustarse a los datos disponibles en este trabajo.

Se consideraron dos modelos tradicionales. Primero, uno basado en el regresor de Bagging [12], el cual es un meta estimador que ajusta los regresores base en subconjuntos aleatorios del conjunto de datos original y luego une sus predicciones individuales para formar una predicción final. Como regresor base se utilizó SVR (*Support Vector Regressor*), el cual trata de seleccionar un hiperplano con el mayor margen posible entre los vectores de soporte identificados a partir de los datos. Este modelo es adecuado cuando se cuenta con una cantidad limitada de datos disponibles, basándose en la identificación de puntos mínimos locales y el reconocimiento de patrones a alto nivel [13]. Segundo, se utilizó un modelo de estimación de series de tiempo VAR (*Vector Autoregression*) [14], el cual es uno de los modelos más utilizados para el análisis de series de tiempo multi-variadas. En este modelo, la estimación de ocupación para el tiempo $t + 1$ depende de las características de P instancias en el pasado.

TABLA I: Configuración de hiper-parámetros

	Valor
Neuronas red GCNN	10 , 12
Características de la capa block embedding	5, 10
Características de la capa hour embedding	5, 10
Características de la capa day embedding	5, 7
Neuronas de la red LSTM	20 , 30
Neuronas de la capa densa	10 , 20

D. Implementación del modelo

A partir del procesamiento de los datos descriptos en la Sección IV-A, se generó la representación para cada uno de los parquímetros para un intervalo de tiempo determinado. Las representaciones para cada intervalo se agruparon en matrices bidimensionales, en las cuales las filas representan los 95 parquímetros/cuadras y las columnas sus características. De esta forma, un día es representado por una lista de matrices (o ventanas), una correspondiente a cada intervalo sin superposición. Por ejemplo, para un día de semana para el cual se consideran intervalos de 30 minutos, se tendrá una lista de 20 matrices, una por cada intervalo.

Para la definición de los intervalos, se consideraron ventanas de tamaño fijo, las cuales representan la cantidad de intervalos anteriores que se tendrán en cuenta para la estimación de ocupación de estacionamiento. Se consideraron distintos tamaños con el objetivo de determinar la importancia de los distintos niveles de información histórica en la estimación de la ocupación. Por ejemplo, si se define un intervalo de tiempo de 5 minutos, a lo largo de 1 hora se calcularán los valores de las características para 12 conjuntos de registros. Asimismo, si se define una ventana de 3 instantes temporales, para estimar la ocupación para un intervalo de tiempo determinado, por ejemplo 12:30 a 12:35, se considerarán las características procesadas en los 3 intervalos anteriores, en este caso: 12:15 a 12:20, 12:20 a 12:25 y 12:25 a 12:30. Considerando los trabajos en la literatura, el tamaño del intervalo también fue variado, entre los 5 y los 20 minutos.

El modelo fue desarrollado en Python. El procesamiento y almacenamiento de los datos fue realizado utilizando NumPy y Pandas, mientras que la implementación del modelo fue realizada utilizando TensorFlow. Todas las ejecuciones fueron realizadas en el entorno Google Colaboratory.

La optimización de hiper-parámetros se enfocó en los tamaños de las capas de bloques, hora y día; además de la cantidad de neuronas en la capa densa, de la red LSTM y de la GCNN. El proceso terminaba cuando no se observaban más cambios en el error. Para realizar la optimización se tomó como base un modelo considerando como características la cantidad de ingresos, egresos y la cantidad total de vehículos estacionados, con un intervalo de análisis de 20 minutos y una ventana de 3 instancias. En total se evaluaron 64 combinaciones de parámetros, como se muestra en la Tabla I (en negrita se muestran los parámetros que permitieron alcanzar los mejores resultados, y por lo tanto fueron seleccionados).

Para la evaluación, se utilizaron dos métricas:

- **MAE** (*Mean Absolute Error*). Calcula el promedio de la diferencia entre los valores estimados y los observados. Todas las diferencias tienen la misma importancia y no se distingue entre sub- o sobre-estimaciones.
- **MSE** (*Mean Squared Error*). Similar a MAE, calcula el promedio de los cuadrados de la diferencia entre los valores estimados y los observados. Debido al cálculo de cuadrados, a mayor error, mayor penalización.

Finalmente, también se realizó un análisis estadístico para determinar si las diferencias observadas entre los modelos eran estadísticamente significativas. Dado que comparar los valores estimados por cada modelo no permite determinar cuál de los modelos es el mejor dado que la estimación por sí misma no da un indicador de cuán buena fue, las comparaciones se hicieron en función de las distribuciones de errores observadas para cada instancia. En el caso del MAE, el error para cada instancia se calculó como la resta entre el valor estimado y el real, mientras que para MSE, se calculó como la resta entre el valor estimado y el real al cuadrado.

V. RESULTADOS DE LA EVALUACIÓN

Esta sección reporta las evaluaciones realizadas para responder a las diferentes preguntas de investigación planteadas.

A. PII. Variación de características y configuraciones.

Para responder esta pregunta se realizaron diversas evaluaciones modificando: 1) las características internas sobre las cuales se entrena el modelo, 2) la longitud de los intervalos de análisis, 3) el número de instancias temporales anteriores (historial), y 4) las características externas a agregar para el entrenamiento del modelo. A partir de cada evaluación se selecciona el mejor modelo para ser utilizado en las evaluaciones sucesivas. En todos los casos, los modelos fueron entrenados y evaluados utilizando las mismas particiones de datos. Para esto, los días fueron divididos en un conjunto de entrenamiento y un conjunto de prueba, tomando el 75% de los días para entrenamiento y el 25% restante para evaluación.

1) Variación de características internas:

En esta primera evaluación, se consideraron como base las siguientes características: id del parquímetro, cantidad de ingresos, cantidad de egresos y cantidad total de vehículos estacionados. Luego, se generaron siete modelos adicionales incluyendo todas las posibles combinaciones de las siguientes características: cantidad de actas de infracción emitidas, tiempo total de estacionamiento y porcentaje de ocupación.

La Tabla II presenta los resultados obtenidos. En todos los casos el modelo base obtuvo resultados significativamente inferiores que los otros modelos, lo que permite inferir la importancia de incorporar más características al modelo. Considerando los errores reportados y el análisis estadístico de las diferencias, los mejores modelos fueron el 3 (incluye el tiempo de estacionamiento) y el 7 (incluye todas las características internas adicionales), los cuales fueron estadísticamente superiores que los otros modelos. Es interesante destacar que si bien el modelo 3 obtuvo menor MSE que el modelo 7, la

TABLA II: Variación de características internas

	Modelo	MAE	MSE
1	Base	1,221	2,9245
2	Actas de infracción	1,2059	2,8589
3	Tiempo estacionado	0,9331	0,6034
4	% de ocupación	1,199	2,8281
5	Tiempo estacionado, actas de infracción	<u>0,9213</u>	1,6
6	Actas de infracción, % de ocupación	1,1947	2,8699
7	Tiempo estacionado, % de ocupación	0,9187	1,6552
8	Tiempo estacionado, actas de infracción, % de ocupación	0,9389	<u>1,578</u>

TABLA III: Variación de la longitud del intervalo

	Modelo	MAE	MSE
7	20 minutos	0,9187	1,6552
9	5 minutos	0,6058	0,5757
10	10 minutos	<u>0,7232</u>	<u>0,604</u>
11	20 minutos	0,8317	1,2774

distribución de errores para el modelo 7 fue significativamente inferior que la del modelo 3. Al analizar la distribución de errores por parquímetro, se observó la existencia de “errores outliers” los cuales causaron la diferencia final en la métrica.

A partir de los resultados obtenidos para esta evaluación, se selecciona el *modelo 7 incluyendo cantidad de actas de infracción emitidas, tiempo total de estacionamiento y porcentaje de ocupación*.

2) Variación de la ventana de análisis:

Como se mencionó anteriormente, las instancias representan un determinado intervalo temporal dividido en ventanas de longitud arbitraria. Tomando como base las características incluidas en el modelo 7, para esta evaluación se consideran 3 longitudes de ventana: 5 minutos (modelo 9), 10 minutos (modelo 10) y 15 minutos (modelo 11).

La Tabla III presenta los resultados obtenidos. Como puede observarse, al igual que lo reportado en otros trabajos de la literatura [4, 7], disminuir la longitud de los intervalos (el modelo 7 considera intervalos de 20 minutos) permite mejorar las estimaciones. En particular, los mejores resultados se obtuvieron considerando intervalos de 5 minutos (modelo 9), el cual superó significativamente a los otros modelos. Estos resultados pueden deberse a que con ventanas más largas, las diferentes instancias presentan una mayor variabilidad en sus características e incluso cambios más abruptos de sus valores entre dos instancias consecutivas. Esto puede causar pérdida de información al querer resumir los eventos en la instancia, lo que puede dificultar la identificación de patrones de ocupación y por ende la calidad de las estimaciones, ya que el futuro se hace más incierto. Por el contrario, con intervalos más pequeños, es esperable que la transición entre instancias sea más fluida y por ende, más fácil de aprender para el modelo.

A partir de los resultados obtenidos, se selecciona el *modelo 9, el cual considera intervalos de 5 minutos*.

TABLA IV: Variación de las instancias de entrenamiento

Modelo	MAE	MSE
9 3 instancias	<u>0,6058</u>	<u>0,5757</u>
12 4 instancias	0,6366	0,5908
13 5 instancias	0,5993	<u>0,5724</u>
14 6 instancias	0,5981	0,5637

3) *Variación de las instancias de entrenamiento:*

Se evaluó también la contribución de la información histórica a las estimaciones mediante la variación de la cantidad de instancias que se consideran en el entrenamiento. Tomando como base el modelo 9, se crearon 3 modelos considerando 4 (modelo 12), 5 (modelo 13) y 6 (modelo 14) instancias. Tener en cuenta que a medida que se incrementa la cantidad de instancias, se limita la utilidad del modelo. Por ejemplo, comenzando a las 10 horas, utilizando cinco instancias, la primera predicción podrá realizarse recién a las 10:25 horas.

La Tabla IV presenta los resultados obtenidos. De acuerdo con lo observado, incrementar la cantidad de instancias en el entrenamiento (el modelo 9 considera 3 instancias), permite mejorar ligeramente las estimaciones. Sin embargo, no se observa una tendencia lineal entre el incremento de instancias y la mejora de las estimaciones, siendo, incluso, no significativas las diferencias. A partir de estos resultados, puede inferirse que hay un límite a la información que aportan las instancias anteriores. Asimismo, considerando entonces, los límites a la utilidad del modelo a medida que se incrementa la cantidad de instancias, resulta conveniente reducirla.

A partir de los resultados obtenidos para esta evaluación, se selecciona el *modelo 13, el cual considera 5 instancias previas para el entrenamiento.*

4) *Variación de características externas:*

Además de variar las características directamente relacionadas al nivel de ocupación de estacionamiento, es posible considerar características externas como los períodos de recesos escolares y el estado meteorológico (como se describió en la Sección IV-A). En este contexto, tomando como base el modelo 13, se crearon diferentes modelos que incorporan distintas combinaciones de características externas. Por ejemplo, se considera la combinación de temperatura y lluvia, ya que, si el día está lluvioso y la temperatura es baja, probablemente se registren menores niveles de ocupación del estacionamiento que si igualmente lloviese pero la temperatura fuese agradable.

Como muestra la Tabla V, la incorporación de nuevas características condujo, en algunos casos, a mejoras en los resultados. Particularmente, las combinaciones de la característica referida a los recesos escolares con alguna de las referidas al estado meteorológico obtuvieron resultados ligeramente inferiores que la consideración por separado del receso escolar y del estado meteorológico. Esto puede deberse a que la distribución de los días de receso es limitada (abarcando 15 días de julio y los meses de enero y febrero) y no uniforme, con lo que gran parte de dicha información puede aprenderse del clima. En este contexto, agregar de forma explícita la información del receso, solo facilitaría que el

TABLA V: Variación características externas (estado meteorológico y receso escolar)

Modelo	MAE	MSE
13 Base & Tiempo estacionado, % de ocupación	0,5993	0,5724
15 Estado meteorológico	<u>0,5885</u>	<u>0,5521</u>
16 Receso escolar	<u>0,586</u>	0,5463
17 Receso escolar, estado meteorológico	0,6071	0,5666
18 Temperatura	0,5955	0,5703
19 Temperatura, precipitaciones	0,6037	0,564
20 Temperatura, lluvia	0,6	0,5644
21 Receso escolar, temperatura	0,6008	0,5675
22 Receso escolar, lluvia	<u>0,5883</u>	0,545
23 Receso escolar, precipitaciones	0,5958	0,5611
24 Receso escolar, viento	0,5057	0,568
25 Receso escolar, tormenta	0,5992	0,562
26 Receso escolar, niebla	0,6075	0,6075

modelo refuerce los patrones aprendidos, pero no incorpore nuevos. El test estadístico mostró que los únicos modelos que superaron estadísticamente al modelo sin características externas fueron los modelos puramente orientados al estado meteorológico (modelo 15) y al receso escolar (modelo 16). De la comparación entre estos modelos, se observan diferencias significativas favoreciendo el modelo 15.

A partir de los resultados obtenidos para esta evaluación, se selecciona el *modelo 15, el cual incorpora todas las características asociadas al estado meteorológico: la temperatura promedio, las precipitaciones totales, la velocidad media del viento, y la presencia o ausencia de lluvia, tormenta y niebla.*

En resumen, las mejores estimaciones fueron realizadas incluyendo características referidas a la cantidad de actas de infracción emitidas, tiempo total de estacionamiento y porcentaje de ocupación, intervalos de 5 minutos, 5 instancias previas para el entrenamiento, y todas las características relacionadas al estado del estacionamiento y meteorológico.

B. P12. Comparación con otros modelos

El mejor modelo obtenido como respuesta a P11 fue comparado con los modelos seleccionados de la literatura descriptos en la Sección IV-C. En el caso de VAR, el modelo fue entrenado únicamente considerando las características relacionadas a la ocupación de los días anteriores similares a los días de evaluación dado que la técnica necesita datos históricos continuos. Asimismo, se consideró una cantidad de instancias de 5, dado que en evaluaciones preliminares dicho valor permitió alcanzar los mejores resultados. Tanto para el regresor como el modelo de Yang et al. [6] se utilizó el mismo conjunto de características que para el modelo presentado.

La Tabla VI presenta los resultados obtenidos para cada modelo. Como puede observarse, el modelo propuesto supera a los otros de forma significativa, con efectos medianos a grandes. En lo que respecta al MAE, el modelo propuesto

TABLA VI: Comparación con otras técnicas
Para MAE y MSE, * indica diferencias estadísticas
significativas favoreciendo el modelo presentado

	MAE	MSE
Modelo propuesto	0,5885	0,5521
Yang et al. [6]	2,4812*	11,6655*
Bagging con SVM	2,6390*	14,5138*
VAR	1,7197*	5,6714*

alcanza diferencias entre el 66% (VAR) y el 78% (Bagging con SVM). Reducciones similares se observan para MSE, donde las diferencias se encuentran en el rango de 90%-96%.

VAR permitió alcanzar los segundos mejores resultados, superando incluso a modelos computacionalmente más complejos como el de Yang et al. [6]. Si bien el modelo de Yang et al. [6] presenta ciertas semejanzas con el modelo propuesto, lo que podría haber sugerido que se obtendrían resultados similares, los resultados obtenidos son significativamente inferiores. Esto puede deberse a que en el modelo original de Yang et al. [6], resultaban más relevantes características que no se tienen disponibles en este caso, como la velocidad del tráfico o el recuento de incidentes, resultando las características del clima y de ocupación previa menos relevantes.

En resumen, la evaluación experimental permite inferir que el modelo propuesto permite mejorar la calidad de las estimaciones de otros modelos de la literatura, mostrando su adecuación para la estimación del estado del estacionamiento.

VI. CONCLUSIONES

En este trabajo se propuso un modelo para la estimación de la ocupación de estacionamiento a nivel cuadra, a partir de la combinación de redes GCNN y LSTM. La evaluación experimental aplicada al contexto de la ciudad de Tandil, Argentina, permitió comprobar que, para este escenario, el modelo desarrollado mejora los resultados de otras técnicas de la literatura. Asimismo, permite inferir que los modelos de predicción pueden beneficiarse en gran medida por la inclusión de variables externas (como el clima), y la incorporación de cierta cantidad de sucesos previos al momento que se quiere predecir. Este estudio también muestra que no es necesario contar con una gran y costosa infraestructura para realizar estimaciones, sino que con la información provista por los parquímetros de la ciudad ya sería posible. A su vez, se expone que es viable predecir la ocupación del estacionamiento en ciudades de tamaño intermedio como Tandil, cuya extensión territorial y cantidad de habitantes es significativamente menor en comparación a los casos de estudio de los trabajos relacionados antes mencionados.

Diferentes aspectos pueden ser abordados en trabajos futuros. En primer lugar, es posible explorar la inclusión de nuevas fuentes de datos. Por ejemplo, se podría utilizar la API de Google Maps para obtener datos sobre el flujo de tránsito, cortes de calles y accidentes. Complementariamente, se podrían utilizar las redes sociales para identificar eventos

en la ciudad (obras de teatro, eventos deportivos, conciertos), junto con su duración y su concurrencia esperada. Segundo, se podría considerar la inclusión de una mayor cantidad de datos históricos, abarcando más de un año. Esto podría permitir la detección de patrones de comportamiento de los habitantes de la ciudad a lo largo de los años, por ejemplo en ciertas fechas específicas como Navidad y demás eventos anuales, lo que permitiría al modelo aprender de dichos comportamientos y potencialmente mejorar la calidad de las estimaciones.

REFERENCES

- [1] R. E. Barone, T. Giuffrè, S. M. Siniscalchi, M. A. Morgano, and G. Tesoriere, "Architecture for parking management in smart cities," *IET Intelligent Transport Systems*, vol. 8, no. 5, pp. 445–452, 2014.
- [2] F. Caicedo, F. Robuste, and A. Lopez-Pita, "Parking management and modeling of car park patron behavior in underground facilities," *Transportation research record*, vol. 1956, no. 1, pp. 60–67, 2006.
- [3] Y. Ji, D. Tang, P. Blythe, W. Guo, and W. Wang, "Short-term forecasting of available parking space using wavelet neural network model," *IET Intelligent Transport Systems*, vol. 9, no. 2, pp. 202–209, 2015.
- [4] E. I. Vlahogianni, K. Kepaptsoglou, V. Tsetos, and M. G. Karlaftis, "A real-time parking prediction system for smart cities," *Journal of Intelligent Transportation Systems*, vol. 20, no. 2, pp. 192–204, 2016.
- [5] X. Chen, "Parking occupancy prediction and pattern analysis," *Dept. Comput. Sci., Stanford Univ., Stanford, CA, USA, Tech. Rep. CS229-2014*, 2014.
- [6] S. Yang, W. Ma, X. Pi, and S. Qian, "A deep learning approach to real-time parking occupancy prediction in transportation networks incorporating multiple spatio-temporal data sources," *Transportation Research Part C: Emerging Technologies*, vol. 107, pp. 248–265, 2019.
- [7] Y. Zheng, S. Rajasegarar, and C. Leckie, "Parking availability prediction for sensor-enabled car parks in smart cities," in *2015 IEEE Tenth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)*. IEEE, 2015, pp. 1–6.
- [8] T. Fabusuyi, R. C. Hampshire, V. A. Hill, and K. Sasanuma, "Decision analytics for parking availability in downtown pittsburgh," *Interfaces*, vol. 44, no. 3, pp. 286–299, 2014.
- [9] Z. Zhao and Y. Zhang, "A comparative study of parking occupancy prediction methods considering parking type and parking scale," *Journal of Advanced Transportation*, 2020.
- [10] A. Ziat, B. Leroy, N. Baskiotis, and L. Denoyer, "Joint prediction of road-traffic and parking occupancy over a city with representation learning," in *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*. IEEE, 2016, pp. 725–730.
- [11] T. N. Kipf and M. Welling, "Semi-supervised classification with graph convolutional networks," in *5th International Conference on Learning Representations, ICLR 2017, Toulon, France, April 24-26, 2017, Conference Track Proceedings*.
- [12] L. Breiman, "Bagging predictors," *Machine learning*, vol. 24, no. 2, pp. 123–140, 1996.
- [13] Y. Guo, A. Graber, R. N. McBurney, and R. Balasubramanian, "Sample size and statistical power considerations in high-dimensionality data settings: a comparative study of classification algorithms," *BMC bioinformatics*, vol. 11, no. 1, pp. 1–19, 2010.
- [14] H. Lütkepohl, *New introduction to multiple time series analysis*. Springer Science & Business Media, 2005.