

MODELOS DE PREDICCIÓN BASADOS EN LA IA PARA LA DISPONIBILIDAD DE APARCAMIENTO URBANO UN ESTUDIO DE CASO EN VALENCIA

FRANCESC DOMENECH¹, VICENTE CAROT¹, CRISTINA PORTALÉS¹, INMACULADA COMA¹

¹UNIVERSITAT DE VALÈNCIA, ESPAÑA

PALABRAS CLAVE	RESUMEN
<i>Predicción de aparcamiento urbano Ciudad Inteligente Inteligencia Artificial Aprendizaje automático Redes neuronales recurrentes</i>	<i>El acceso eficiente al aparcamiento es crucial para la movilidad urbana en las ciudades inteligentes. Este estudio presenta un sistema piloto de predicción de la ocupación de aparcamientos públicos en Valencia, España, utilizando datos de sensores municipales. Desarrollamos y comparamos arquitecturas de redes neuronales recurrentes (RNN, LSTM, GRU), logrando previsiones precisas con variaciones de rendimiento entre ubicaciones y horas. Los métodos aplicados con la IA permitieron interpretar los modelos y comprender la influencia de las variables. Los resultados indican que los modelos de referencia producen MAE bajos, mientras que la optimización bayesiana de hiperparámetros sólo ofrece ventajas marginales, lo que pone de relieve la viabilidad de los enfoques recurrentes sencillos para la predicción de aparcamientos urbanos.</i>

Recibido: 16 /08 /2025

Aceptado: 28 /09 / 2025

1. Introducción

El aumento de la densidad urbana y el creciente número de vehículos plantean importantes retos para la gestión del aparcamiento en ciudades grandes y medianas como Valencia. La búsqueda ineficiente de plazas de aparcamiento aumenta la congestión, el consumo innecesario de combustible y las emisiones contaminantes (Shoup, 2005). Como parte del movimiento «ciudades inteligentes», los ayuntamientos están explorando soluciones basadas en datos y tecnologías emergentes (Batty et al., 2012). Los gobiernos locales han elaborado guías, como *Movilidad Transformadora* (2024), para recoger las mejores prácticas en gestión de aparcamientos y una movilidad sostenible. También han impulsado iniciativas tecnológicas, como el proyecto *Aparcamiento Inteligente* en el PCT Cartuja (Junta de Andalucía & Telefónica, 2021), que aprovechan la monitorización de la ocupación en tiempo real a través de cámaras e informan a los usuarios mediante aplicaciones móviles y paneles de visualización. Una de las posibles aplicaciones es optimizar el uso de las plazas de aparcamiento disponibles y mejorar la experiencia de los conductores.

La ciudad de Valencia cuenta con un sistema que permite monitorizar en tiempo real el número de plazas disponibles en un conjunto de aparcamientos públicos. Esta información está disponible en la plataforma de datos abiertos del Ayuntamiento de Valencia y se muestra en los paneles informativos distribuidos en diferentes puntos de la ciudad, ayudando a gestionar la movilidad urbana de forma más eficaz.

Este trabajo presenta una evaluación exhaustiva de algoritmos para predecir la disponibilidad de aparcamiento en Valencia. Los modelos propuestos pronostican qué aparcamientos es probable que tengan plazas disponibles en días y horas específicos, utilizando datos históricos, patrones de comportamiento y técnicas de aprendizaje automático. Su implementación puede ayudar a una gestión más eficiente de la movilidad y contribuir a objetivos más amplios de sostenibilidad y calidad de vida en las áreas metropolitanas.

Partiendo de datos históricos de uso proporcionados por el Ayuntamiento de Valencia, desarrollamos un sistema escalable capaz de predecir la disponibilidad de aparcamientos públicos utilizando métodos de *deep learning*. El estudio compara el rendimiento de tres arquitecturas de redes neuronales recurrentes (RNN) —RNN básica, LSTM y GRU— tanto en su forma básica como optimizada, esta última obtenida mediante el ajuste bayesiano de hiperparámetros. Para mejorar la interpretabilidad, se emplea un modelo sustituto para identificar las variables con mayor influencia en las predicciones.

Una vez verificada la validez de la solución propuesta, se integrarán los nuevos datos de ocupación de aparcamientos generados en tiempo real para optimizar sus predicciones mediante despliegues y entrenamientos automatizados.

Este artículo se organiza como sigue. En primer lugar, en la Sección 2 se realiza una revisión del estado de las técnicas de predicción de la disponibilidad de plazas de aparcamiento. En la Sección 3 se detalla la metodología seguida para el análisis de los datos y la aplicación de los modelos de predicción. En la Sección 4 se analizan y discuten los resultados obtenidos en los diferentes modelos y se comparan los resultados con trabajos anteriores. En la Sección 5 se explican los resultados obtenidos con el modelo de la IA. Por último, en la Sección 6 se muestran las conclusiones y el trabajo futuro.

2. Técnicas de predicción

El desarrollo de sistemas para predecir la disponibilidad de plazas de aparcamiento se enmarca en la evolución de las ciudades inteligentes, cuyo objetivo es optimizar los servicios urbanos mediante el

uso de tecnologías avanzadas de la información, la comunicación (Batty et al., 2012) y sistemas de inteligencia artificial.

En los últimos años, se han explorado diversos enfoques para predecir la disponibilidad de plazas de aparcamiento, combinando sensores IoT, análisis de datos históricos y técnicas de inteligencia artificial (IA). Las técnicas de IA para predecir la disponibilidad de aparcamiento aprovechan una variedad de modelos de aprendizaje automático (ML) y aprendizaje profundo (DL) para mejorar la precisión y la eficiencia. Estos modelos utilizan una variedad de datos, incluidas las tasas de ocupación históricas y los factores contextuales, para pronosticar las plazas de aparcamiento disponibles.

Diferentes estudios demuestran el potencial del análisis de series temporales en contextos urbanos, incluida la movilidad a partir de datos de telefonía móvil (Calabrese et al., 2011) o datos recogidos de infraestructuras de red omnipresentes (Zheng et al., 2015). Pozo et al., (2022) desarrolló un predictor de aparcamiento urbano en Madrid, España, utilizando los datos de ocupación recogidos de infraestructuras de aparcamiento inteligentes y Moreno (Moreno Esteban, 2021) realizó un estudio de predicción de ocupación para varios aparcamientos alrededor de estaciones de tren en la provincia de Barcelona, mostrando patrones cíclicos diarios en el uso.

Los modelos tradicionales de aprendizaje automático se han aplicado a la predicción de disponibilidad de aparcamientos debido a su simplicidad e interpretabilidad. Estos modelos incluyen Decision Trees (DT), Random Forest (RF), K-Nearest Neighbors (KNN), y otros. Algunos estudios han demostrado que estos algoritmos más simples a menudo superan a modelos más complejos como el Perceptrón Multicapa (MLP) en términos de precisión de predicción (Awan et al., 2020; Inam et al., 2022).

Los modelos de aprendizaje profundo *Deep Learning* han acaparado una gran atención en los últimos años debido a su capacidad para aprender patrones complejos de los datos. Así, las redes neuronales se han utilizado para predecir la disponibilidad de plazas de aparcamiento relacionando diversos factores como la hora, el tiempo y las condiciones del tráfico. Por ejemplo, un estudio realizado con datos del proyecto SFpark en San Francisco demostró que las redes neuronales superaban a otros modelos tradicionales de previsión de series temporales como ARIMA y SARIMA en términos de error cuadrático medio, especialmente cuando se tenían en cuenta variables exógenas como el tipo y la hora del día (Sebatli, 2023). Se han empleado redes neuronales y redes temporales para captar tanto las características espaciales como las temporales, lo que ha permitido mejorar los resultados de las predicciones (Chen et al., 2023; Zhang et al., 2024).

Del mismo modo, las arquitecturas basadas en redes neuronales recurrentes (RNN) y sus variantes, como las de memoria a corto plazo (LSTM) (Hochreiter y Schmidhuber, 1997) y las unidades recurrentes controladas (GRU) (Cho et al., 2014), se adaptan bien a las tareas de predicción de series temporales, lo que las convierte en una opción natural para la predicción de la disponibilidad de aparcamientos. Las LSTM, en particular, han demostrado un buen rendimiento en la predicción de series temporales a largo plazo, incluyendo problemas relacionados con la predicción de la ocupación de aparcamientos utilizando datos históricos y condiciones de tráfico (Barraco et al., 2021; Vieta, 2024; Yuen et al., 2021). Asimismo, las GRU se han utilizado para modelar las relaciones espaciales entre los aparcamientos y la dinámica temporal de los comportamientos de aparcamiento (Zhao & Zhang, 2024).

A pesar de estos avances, persisten varios retos. Por un lado, la calidad y disponibilidad de los datos históricos en tiempo real pueden ser limitadas o heterogéneas (Zheng et al., 2014). Por otro, la variabilidad asociada a factores contextuales como acontecimientos culturales, cambios en la oferta de transporte público o condiciones meteorológicas sigue siendo difícil de modelar con precisión (Yang et al., 2019).

La necesidad de interpretabilidad de los modelos de IA es otro aspecto fundamental para analizar cuando se utilizan estos sistemas de predicción. Una estrategia eficaz es el uso de modelos

aproximadores sencillos e intrínsecamente interpretables (por ejemplo, árboles de decisión o regresiones lineales) entrenados para imitar el comportamiento de un modelo de «caja negra» más complejo. Analizando la estructura del modelo sustituto o la importancia de sus características, podemos saber qué datos determinan las predicciones del modelo original.

En resumen, la literatura muestra una clara tendencia hacia el uso de técnicas de aprendizaje profundo para resolver el problema de la predicción de la disponibilidad de aparcamiento en entornos urbanos. El presente trabajo se enmarca en esta línea, evaluando el uso de RNN, LSTM y GRU sobre datos reales de la ciudad de Valencia, y proporcionando una comparación sistemática entre arquitecturas básicas y versiones optimizadas. También incorpora técnicas de interpretabilidad para mejorar la comprensión y aplicabilidad de los resultados en sistemas de gestión de la movilidad urbana.

En el caso concreto de las ciudades españolas, el caso de Valencia resulta especialmente interesante, dada la disponibilidad de datos públicos y la progresiva implantación de sistemas de movilidad inteligente.

3. Metodología

En este apartado se describe la metodología seguida en el presente trabajo. En primer lugar, se analizan y preprocesan los datos recogidos para eliminar valores erróneos o ausentes. A continuación, se realiza un análisis exploratorio de los datos. Por último, el conjunto de datos se utiliza para ensayar un modelo predictivo basado en redes neuronales. En las siguientes subsecciones se describen con más detalle estos pasos.

3.1. Recogida y descripción de datos

El Ayuntamiento de Valencia publica en su portal de datos abiertos información en tiempo real sobre la disponibilidad de plazas en los aparcamientos públicos de la ciudad. Además, aunque el histórico de uso de los aparcamientos no se publica en dicho portal, el ayuntamiento a través de la oficina Smart City almacena esta información. Los elementos utilizados como punto de partida para este trabajo son:

- Fichero CSV con los datos de plazas de aparcamiento que abarcan el periodo específico de cada instalación.
- Fichero CSV con el identificador y nombre de los aparcamientos.

Estos ficheros contienen información sobre 20 aparcamientos, que se utilizan en el análisis que se detalla a continuación. Para mayor claridad de la presentación, en este documento sólo se muestran los resultados de uno o dos aparcamientos, aunque el método se aplica a todo el conjunto.

3.2. Preparación de los datos

El fichero con la información sobre las plazas de aparcamiento contiene 13 millones de registros, correspondientes a los 20 aparcamientos. Es habitual que grandes cantidades de datos contengan valores erróneos, no válidos o ausentes. Por lo tanto, el primer paso es realizar una inspección inicial y una limpieza de los datos.

El archivo de datos proporcionado contiene las siguientes columnas (tabla 1):

Tabla 1. Información del conjunto de datos	
Nombre	Significado
Id	ID del aparcamiento (alfanumérico)
entityId	id del aparcamiento

entityType	tipo de aparcamiento
availableSpotNumber	número total de plazas de aparcamiento disponibles
availableSpotPercentage	porcentaje de plazas disponibles
totalSpotNumber	número total de plazas de aparcamiento
idParking	Identificador del aparcamiento
recvTime	hora de grabación de los datos
TimeInstant	hora de recepción de los datos


Fuente: Elaboración propia, 2025.

El conjunto de datos se somete a los siguientes pasos de procesamiento:

1. Se eliminan todas las columnas redundantes o que contienen gran cantidad de datos ausentes, ya que no se utilizan en el análisis, quedando: availableSpotNumber, totalSpotNumber e idParking.
2. Se realizan las conversiones de tipo necesarias: por ejemplo, se corrigen los registros que se refieren al mismo aparcamiento, pero tienen identificadores diferentes debido a un registro erróneo.
3. Otra incoherencia corregida afecta a los registros en los que el número total de plazas de aparcamiento varía para una misma ubicación.
4. Si hay pocos registros erróneos para un aparcamiento, se corrigen, ya que se interpretan como errores de transmisión, y si hay muchos, se descartan los datos de ese aparcamiento.

A continuación, se define una función para mostrar el intervalo de tiempo de cada aparcamiento (véase la figura 1), así como los periodos con datos ausentes, que se interpolan linealmente. También se identifican los registros erróneos, es decir, aquellos cuya disponibilidad es superior al número total de plazas de aparcamiento o la disponibilidad es negativa

Figura 1. Ejemplo de datos recogidos para el aparcamiento con ID = 78 - Severo Ochoa
Parking ID: 78



Fuente: Elaboración propia, 2025.

Esta función de depuración de datos se aplica para cada aparcamiento, y se eliminan todos los registros asociados en los que hay largos periodos de datos perdidos, ya que imputar periodos tan largos puede comprometer la calidad de los resultados. También se suprimen aquellos en los que los datos son escasos o incorrectos.

Con el análisis realizado hasta ahora, los principales problemas detectados en los datos recibidos son:

- Registros de un mismo aparcamiento asociados a diferentes identificadores, aunque debería ser el mismo.
- Registros de un mismo aparcamiento en los que varía el número de plazas totales.
- Registros erróneos (donde el número de plazas disponibles es negativo o supera el número total de plazas).
- Registros con los datos incorrectos.

A partir del análisis realizado hasta el momento, se identifican los principales problemas en los datos recibidos:

- Varios registros asociados a la misma franja horaria, en este caso se calcula la media de estos registros.
- Franjas horarias sin registros (valores perdidos, NA). Aquí se utiliza una media ponderada entre los 4 registros anteriores y ese mismo registro, a la misma hora, en la semana anterior.
- Si aparecen muchos valores perdidos al principio de la serie, se utilizarán los datos cuando los valores nulos se reduzcan significativamente, para no comprometer el resultado de las predicciones, ya que imputar periodos largos puede ser peligroso.

Aplicando estas correcciones para cada aparcamiento se eliminan los registros que puedan contener datos erróneos.

En resumen, al final de esta etapa se obtienen datos sin irregularidades: un único dato por hora desde el principio hasta el final de la serie temporal. Se obtiene un fichero de salida que mantiene 3 variables: el identificador del aparcamiento, el porcentaje de plazas disponibles en un rango entre 0 y 100, y el instante de tiempo al que se refiere el registro.

3.3. Análisis exploratorio de datos y periodograma


Esta etapa proporciona una comprensión inicial de cómo se distribuyen los datos, permitiendo detectar patrones temporales repetitivos e identificar cuándo y cómo cambia la ocupación a lo largo del tiempo. Para ello, se aplican dos técnicas: el análisis exploratorio de datos (AED) y un periodograma para estudiar los datos en el dominio de la frecuencia.

En el AED, se calcula el porcentaje de plazas disponibles (de 0 a 100) para cada aparcamiento, con los datos agregados por día del mes, día de la semana y mes del año.

A modo de ejemplo, se presentan los resultados del análisis exploratorio de datos de dos aparcamientos representativos.

En el caso del aparcamiento ID 6 (Figura 2), la disponibilidad disminuye durante los fines de semana, lo que sugiere un uso para compras y actividades de ocio, mientras que el aumento en agosto refleja una menor demanda durante la temporada de vacaciones. Por el contrario, el aparcamiento ID 7 muestra una mayor disponibilidad tanto los fines de semana como en agosto, lo que indica un uso predominante durante las horas de trabajo, con una mayor ocupación los días laborables y una menor demanda durante los periodos de menor actividad profesional.

Figura 2: Análisis EDA de 2 aparcamientos




Fuente: Elaboración propia, 2025.

Aunque el análisis exploratorio de datos proporciona información valiosa, puede resultar insuficiente para detectar comportamientos periódicos. Para resolver este problema, se calculó un periodograma (Figura 6), transformando los datos del dominio temporal al dominio de la frecuencia

para evaluar la importancia de cada componente. Cada barra del gráfico muestra qué frecuencia es la más importante en la serie temporal. Si la barra es alta, significa que esa frecuencia destaca y puede indicar que hay patrones que se repiten, todos los días, todos los mediodías, etc.

En el caso del aparcamiento ID 6, se producen ciclos notables a las 24, 28 y 12 horas, lo que podría corresponder a rutinas diarias, patrones irregulares como horarios de trabajo a tiempo parcial o escolares, y transiciones entre turnos de trabajo.

Figura 3: Periodograma del aparcamiento con ID = 6



Fuente: Elaboración propia, 2025.

3.4. División y características del conjunto de datos

El conjunto de datos depurado y preprocesado se utiliza para probar un modelo predictivo de ocupación de aparcamientos. La variable es el porcentaje de plazas de aparcamiento disponibles, escalado de 0-100 a 0-1 para mejorar la convergencia y acelerar el ensayo. Se incorporan tres variables categóricas -día de la semana, mes e indicador de fin de semana- para proporcionar información contextual. Estas características categóricas se codifican mediante capas, que permiten al modelo aprender representaciones vectoriales densas y captar las relaciones entre categorías.

Las redes neuronales recurrentes (RNN) se seleccionan por su capacidad para procesar datos secuenciales y aprovechar la información pasada para predecir valores posteriores. La entrada del modelo consistió en ventanas temporales de 24 horas, que se determinaron a partir de los patrones periódicos identificados durante el análisis exploratorio de datos. Cada ventana contenía las 24 horas anteriores a una hora determinada y se utilizaba para predecir la disponibilidad en ese momento.

El método de retención se aplica para dividir el conjunto de datos en subconjuntos de entrenamiento (70%), validación (15%) y prueba (15%). El conjunto cubre un intervalo de tiempo idéntico para todos los aparcamientos y garantizar la comparabilidad del rendimiento, mientras que los subconjuntos de entrenamiento y validación se ajustaron individualmente en función de la disponibilidad de datos de cada aparcamiento.

El modelo se entrena utilizando datos de aparcamientos con ID 6, 7, 8, 13, 34, 75, 77 y 78, empleando valores de disponibilidad reescalados e incrustaciones categóricas en secuencias de entrada de 24 horas.


3.5. Modelización y evaluación

Los modelos se entrenan utilizando tres arquitecturas de redes neuronales (Figura 4):

- Redes neuronales recurrentes (RNN): La arquitectura más básica, que consiste en una capa oculta que se retroalimenta a sí misma en cada paso temporal. Las RNN manejan secuencias cortas con eficacia, pero tienen una retención de memoria a largo plazo limitada.
- Memoria larga a corto plazo (LSTM): Variante de RNN diseñada para retener información a largo plazo. Incorpora tres puertas de control -olvido, entrada y salida- y una célula de memoria interna para regular el flujo de información. Aunque son capaces de captar dependencias a largo plazo, las LSTM son más costosas desde el punto de vista computacional.
- Unidad Recurrente Controlada (GRU): Una alternativa más ligera a las LSTM, con menos parámetros y un entrenamiento más rápido. Utiliza una puerta de actualización y una puerta de reinicio para controlar el flujo de información, logrando un rendimiento competitivo con una complejidad reducida.

El objetivo es comparar la versión básica de cada arquitectura, sin modificaciones (una sola capa, 32 neuronas por capa, sin optimizaciones) con una versión obtenida mediante optimización bayesiana de hiperparámetros, que fue seleccionada frente a la búsqueda aleatoria por su mayor eficiencia en la exploración del espacio de búsqueda. En aprendizaje automático, esta versión básica y no modificada de un modelo suele denominarse «modelo vainilla». Utilizaremos este término para referirnos a una línea de base antes de añadir características u optimizaciones personalizadas.

Figura 4: Arquitectura de las redes neuronales utilizadas



Fuente: Hasan, 2020.

El proceso de ajuste de hiperparámetros para los modelos optimizados considera ajustes en la tasa de aprendizaje, el número de capas y el número de neuronas por capa. Las configuraciones de hiperparámetros probadas para cada enfoque se muestran en la Tabla 2

Tabla 2. Parámetros propuestos en cada arquitectura

Parámetro	Valor	Óptimo
Optimizador	Adam	Adam
Tamaño de lote	32	32
Tasa de aprendizaje	0.001	[0.005-0.02]
Decaimiento del peso	0.05	0.05
Abandono	0.2	0.2
Número de capas	1	[2,3,4]
Número de neuronas por capa	32	[16,32,64]

Fuente: Elaboración propia, 2025.

4. Resultados y discusión


4.1. Evolución de la función de pérdida

En la modelización predictiva, la función de pérdida cuantifica la discrepancia entre las predicciones de un modelo y los valores reales observados, guiando el proceso de optimización durante el entrenamiento. Al minimizar la pérdida, el modelo ajusta iterativamente sus parámetros para mejorar tanto la precisión como la generalización. En el contexto de la predicción de plazas de aparcamiento, la función de pérdida sirve como indicador clave de la eficacia con la que el modelo capta los patrones de ocupación y pronostica la disponibilidad a lo largo del tiempo.

Para el aparcamiento ID 6 con una arquitectura de red neuronal recurrente (RNN), las curvas de pérdidas de entrenamiento y validación (Figura 5) muestran un pronunciado descenso durante las épocas iniciales, estabilizándose en valores cercanos a cero (aproximadamente 0,002-0,003). La divergencia mínima entre las pérdidas de entrenamiento y validación indica una convergencia estable y un sobreajuste insignificante.

Este comportamiento se debe probablemente a dos factores clave. En primer lugar, el rango limitado de las variables de entrada estabilizó la dinámica de activación de la red neuronal. En segundo lugar, la aplicación de la parada anticipada puso fin al entrenamiento cuando las mejoras se estancaron, reduciendo así los cálculos innecesarios y mitigando el riesgo de sobreajuste.

Figura 5: Evolución de las pérdidas de entrenamiento y validación para el aparcamiento ID 6 utilizando el modelo RNN.




Fuente: Elaboración propia, 2025.

4.2. Rendimiento del modelo de referencia: Error medio absoluto (MAE)

Se seleccionó el Error Medio Absoluto (MAE) como métrica de evaluación debido a su interpretabilidad. El MAE representa la desviación absoluta media entre los valores predichos y los reales, independientemente de la dirección, y proporciona una medida directa de la precisión de la predicción. Es importante destacar que, en este trabajo, la MAE se expresó como porcentaje de espacios ocupados en lugar de como recuentos absolutos. Por ejemplo, un MAE del 2,4% para el aparcamiento 13 en el modelo GRU correspondía aproximadamente a 5,49 plazas de una capacidad total de 229 plazas.

En la figura 6 se muestran los resultados MAE de los modelos de referencia (vainilla). De este análisis se desprenden varias observaciones. Algunos aparcamientos mostraron errores de predicción más elevados, en particular el aparcamiento 34, que alcanzó un MAE del 4,0% con la arquitectura GRU. En cambio, los aparcamientos 13 y 8 arrojaron MAE del orden del 2,2-2,3%, lo que sugiere patrones de ocupación muy regulares. En cuanto a la comparación de arquitecturas, LSTM y GRU ofrecieron un rendimiento comparable, superando en general a la red multicapa (MN) más sencilla.

Figura 6: Error absoluto medio por aparcamiento y arquitectura del modelo (configuración vainilla).



Fuente: Elaboración propia, 2025.


4.3. Rendimiento optimizado del modelo: Ajuste bayesiano de hiperparámetros

La optimización bayesiana mediante Optuna se empleó para refinar los hiperparámetros de las arquitecturas RNN, LSTM y GRU. Los resultados (Figura 7) indicaron una mejora general, ya que en la mayoría de las combinaciones aparcamiento-modelo la optimización produjo valores MAE más bajos, confirmando el beneficio del ajuste de hiperparámetros.

Sin embargo, las ganancias fueron generalmente modestas, lo que refleja la naturaleza relativamente regular y predecible de los patrones de ocupación en el conjunto de datos.

Una excepción notable fue el aparcamiento 34 con el modelo GRU, que mostró un rendimiento degradado, con un MAE que aumentó del 4,0% al 6,9%, lo que indica sensibilidad a las configuraciones de hiperparámetros y un posible sobreajuste. A pesar de ello, la mayoría de los modelos optimizados lograron MAE inferiores al 3%, cumpliendo el umbral para su despliegue en tiempo real.

Figura 7: Error absoluto medio por aparcamiento y arquitectura del modelo tras la optimización bayesiana.



Fuente: Elaboración propia, 2025.

4.4. Dinámica y fidelidad de la predicción

La figura 8 subraya la capacidad de los modelos RNN, LSTM y GRU, tanto los simples como los optimizados, para captar la periodicidad de la ocupación de los aparcamientos con una fina resolución temporal.


Incluso sin optimización, todos los modelos siguieron de cerca los patrones cíclicos, lo que indica que la estructura temporal dominante se podía aprender fácilmente a partir de los datos históricos.

Las configuraciones optimizadas obtenidas mediante la búsqueda bayesiana tendieron a ajustarse mejor a las transiciones de picos y valles, en particular durante los cambios bruscos de ocupación (por ejemplo, en torno a las horas 30-40 y 120-140), donde los modelos vainilla mostraron un ligero desfase o subestimación.

Las discrepancias entre las predicciones y los valores reales fueron más visibles durante las desviaciones bruscas y de corta duración del ciclo principal, probablemente causadas por acontecimientos atípicos o perturbaciones de la demanda no recogidas totalmente por los datos de entrenamiento.

Dada la escasa diferencia de rendimiento, la elección entre los modelos vainilla y los optimizados no parece depender tanto de la precisión como de las limitaciones informáticas, los requisitos de latencia y la facilidad de reentrenamiento en entornos de producción.

Figura 8: Predicciones de la primera semana del conjunto de pruebas para el aparcamiento ID = 6
Predictions vs True Series – Parking parking_6 (First Week)



Fuente: Elaboración propia, 2025.

En todos los modelos y aparcamientos, la optimización de hiperparámetros mediante la búsqueda bayesiana produjo reducciones coherentes de MAE en comparación con las configuraciones vainilla. Sin embargo, las mejoras fueron modestas, lo que refleja la naturaleza relativamente regular y predecible de los patrones. En algunos casos, la sobrecarga computacional de los modelos más complejos puede compensar sus ganancias marginales de precisión, especialmente en escenarios de despliegue en tiempo real.

4.5. Implicaciones para el despliegue y la escalabilidad

Los resultados confirman la viabilidad de aplicar redes neuronales recurrentes a la previsión de ocupación de aparcamientos urbanos. Aunque la optimización de los hiperparámetros mejora la precisión en la mayoría de los casos, las modestas mejoras, junto con el aumento de los costes computacionales, sugieren que los modelos de vainilla ya pueden ser suficientes para contextos operativos, especialmente cuando los recursos computacionales son limitados.

Esta metodología, validada en la ciudad de Valencia, se está integrando actualmente en los sistemas de información en tiempo real del Ayuntamiento, lo que permite predecir los datos de ocupación para uso público. Más allá de este caso concreto, el enfoque podría adaptarse a otras ciudades con una disponibilidad de datos similar, ofreciendo beneficios potenciales en la gestión del tráfico, la planificación de la movilidad urbana y la política de transporte sostenible.

4.6. Comparación con trabajos anteriores

Nuestros resultados se alinean y amplían la investigación previa sobre la predicción de la disponibilidad de aparcamiento dentro de una agenda más amplia de las ciudades inteligentes (Batty et al., 2012). En consonancia con la evidencia de que las series temporales de movilidad urbana son susceptibles de predicción basada en datos (Calabrese et al., 2011; Zheng et al., 2015), observamos patrones de ocupación predecibles en todas las instalaciones, reflejados en curvas de pérdida convergentes y bajos errores de validación.

Estudios anteriores han informado de que los modelos de aprendizaje automático relativamente sencillos pueden, en determinados contextos, superar a arquitecturas de redes neuronales más

complejas (Awan et al., 2020; Inam et al., 2022). Nuestros resultados perfeccionan esta perspectiva: los modelos recurrentes de referencia (RNN, LSTM y GRU) ya consiguen MAE bajos - aproximadamente un 2-3% para la mayoría de los aparcamientos- y la optimización bayesiana de los hiperparámetros sólo aporta mejoras marginales. Este resultado concuerda con la bibliografía general, que sugiere que cuando las señales presentan una fuerte regularidad y periodicidad, como es típico en la demanda de aparcamiento, el aumento de la complejidad arquitectónica ofrece rendimientos decrecientes a menos que se complemente con covariables más ricas y diversas.

En cuanto a las LSTM y GRU, trabajos anteriores demuestran que se adaptan bien a las dependencias de largo alcance en series temporales de aparcamiento y tráfico (Barraco et al., 2021; Cho et al., 2014; Hochreiter & Schmidhuber, 1997; Zhao & Zhang, 2024). Nuestra comparación entre modelos lo corrobora: LSTM y GRU funcionan de forma similar y ligeramente mejor que una red multicapa más simple de referencia, con una generalización estable. Esta estabilidad es coherente con las buenas prácticas descritas en la bibliografía (entradas limitadas y parada temprana), que mitigan la explosión/desvanecimiento de grados y el sobreajuste en modelos recurrentes.

Los estudios que aprovechan las características contextuales (por ejemplo, el tipo de día, la hora, el clima) informan de que las redes neuronales pueden superar las líneas de base de series temporales clásicas, como ARIMA/SARIMA (Sebatli, 2023), y que las arquitecturas que capturan la estructura temporal -y a veces espacial- (por ejemplo, las redes convolucionales temporales) pueden mejorar aún más la precisión (Chen et al., 2023; Zhang et al., 2024). Nuestros resultados, obtenidos con redes recurrentes y el conjunto de características disponible, alcanzan tasas de error bajas. Esto sugiere que, para muchas instalaciones, la estructura periódica domina la señal. No obstante, los casos «difíciles» persistentes (por ejemplo, Aparcamiento 34) se hacen eco de hallazgos anteriores según los cuales la variabilidad del contexto puede erosionar el rendimiento (Yang et al., 2019; Zheng et al., 2014). En tales entornos, es probable que la incorporación de variables exógenas y/o el acoplamiento espacial (por ejemplo, instalaciones vecinas, eventos, oferta de tránsito) cierre la brecha señalada en la literatura.

La búsqueda bayesiana de hiperparámetros aporta reducciones de MAE pequeñas pero consistentes para la mayoría de las instalaciones, aunque con una sensibilidad notable en los valores atípicos (por ejemplo, GRU en el aparcamiento 34). Esto concuerda con los informes que indican que las mejoras derivadas de un ajuste avanzado o de arquitecturas más profundas pueden ser incrementales en comparación con su coste computacional, especialmente para el despliegue en tiempo real, lo que respalda la elección pragmática de RNN/LSTM/GRU bien regularizadas cuando la latencia y la capacidad de mantenimiento son importantes.

5. Explicabilidad de la IA

Cuando se aplican modelos de Inteligencia Artificial (IA) y Aprendizaje Automático (AM), la interpretabilidad es crucial para comprender y validar los resultados. La IA explicable (XAI) se refiere a técnicas y métodos que hacen que los procesos de toma de decisiones de los sistemas de IA sean comprensibles para los humanos.

En este trabajo se utilizaron dos enfoques de explicabilidad complementarios: SHapley Additive exPlanations (SHAP) y los modelos sustitutos.


5.1. Análisis SHAP

SHAP, basado en la teoría de juegos, estima la contribución marginal de cada variable de entrada a una predicción específica. Para ello, evalúa todas las combinaciones posibles de características y mide el cambio en el resultado del modelo cuando se incluye o excluye cada variable.

En nuestro caso, el modelo se basa en los datos de ocupación de las 24 horas anteriores. SHAP calcula la contribución de todas las combinaciones de estos instantes a la predicción en tiempo real.

La figura 9 muestra los valores de SHAP para el modelo LSTM vainilla aplicado al aparcamiento ID 6. Los resultados indican que los 10-12 instantes más recientes son los que más influyen en la predicción, en contraste con los resultados del análisis exploratorio de datos (AED), que sugerían que los 24 instantes anteriores eran relevantes. Esto sugiere que la ventana temporal de entrada podría reducirse a la mitad sin degradar significativamente la precisión, lo que reduciría el coste computacional.


Figura 9: Valores SHAP del aparcamiento ID 6, modelo LSTM vainilla



Fuente: Elaboración propia, 2025.

Además, las distribuciones de variables categóricas (Figura 10) revelan que los meses con comportamientos similares se agrupan en el espacio vectorial, corroborando los patrones identificados en el EDA.

Figura 10: Distribuciones de incrustación para variables categóricas



Fuente: Elaboración propia, 2025.

5.2. Análisis de modelos alternativos

Se empleó un modelo alternativo para aproximar el comportamiento de la red neuronal de «caja negra» mediante un modelo más sencillo e interpretable, en este caso, un árbol de decisión de regresión.

Sea $X \in \mathbb{R}^{n \times d}$ las características de entrada y $y_{\text{true}} \in \mathbb{R}^n$ las etiquetas verdaderas. Las predicciones LSTM son:

$$\hat{y}_{\text{LSTM}} = \text{LSTM}(X, y_{\text{true}})$$

Con residuos:


$$e_{\text{LSTM}} = y_{\text{true}} - \hat{y}_{\text{LSTM}}$$

Se entrena un árbol de regresión en $(X, \hat{y}_{\text{LSTM}})$ para imitar las predicciones del LSTM:

$$\hat{y}_{\text{TREE}} = \text{TREE}(X, \hat{y}_{\text{LSTM}})$$

El árbol resultante (Figura 11) destaca las principales características. El análisis confirma que los instantes temporales más recientes dominan las predicciones, excepto durante las horas punta de tráfico (por ejemplo, el inicio y el final de la jornada laboral), cuando los cambios de ocupación son más bruscos y adquieren relevancia dependencias temporales ligeramente más largas. Estos resultados corroboran el beneficio potencial de reducir la ventana temporal de entrada para mejorar la eficiencia computacional sin sacrificar la precisión.

Figura 11: Árbol de decisión alternativo para el modelo RNN optimizado, aparcamiento ID 6



Fuente: Elaboración propia, 2025.

5.3. Limitaciones

El análisis pone de manifiesto ciertas limitaciones del enfoque actual. Factores contextuales como eventos especiales, actividades culturales o cierres de carreteras no se incluyen en el modelo, a pesar de que pueden afectar significativamente a la demanda de aparcamiento. Además, los datos disponibles no están distribuidos uniformemente por todas las zonas de la ciudad, lo que podría afectar a la generalización de los resultados de explicabilidad.

6. Conclusiones y trabajo futuro

Este estudio demuestra la viabilidad de utilizar técnicas de aprendizaje automático para predecir la disponibilidad de plazas de aparcamiento en entornos urbanos, alcanzando un nivel de precisión que permite su integración en aplicaciones de movilidad inteligente. El sistema desarrollado, aplicado a

aparcamientos públicos de la ciudad de Valencia, se basa en arquitecturas de redes neuronales recurrentes e incorpora tanto configuraciones optimizadas como de referencia.

Se llevó a cabo un exhaustivo proceso de adquisición y preprocesamiento de datos, identificando y abordando múltiples limitaciones que podrían haber comprometido la calidad de la predicción. Este trabajo preliminar resultó esencial para garantizar la robustez y fiabilidad del sistema final.

La evaluación de tres arquitecturas recurrentes —RNN, LSTM y GRU— demostró que todas son capaces de captar patrones cíclicos de ocupación con gran precisión. Aunque el ajuste de hiperparámetros mediante optimización bayesiana produjo mejoras modestas, incluso las configuraciones vainilla funcionaron satisfactoriamente, logrando un equilibrio entre precisión predictiva y coste computacional.

Nuestros resultados son congruentes con los trabajos previos que muestran que los modelos recurrentes son un fuerte valor por defecto para las series temporales de ocupación de aparcamientos y que una línea base simple y bien regularizada puede ser suficiente para la mayoría de las instalaciones.

Las técnicas de explicabilidad, incluidos el análisis SHAP y los modelos sustitutos, proporcionaron información valiosa sobre el proceso de toma de decisiones de los modelos, aclarando la influencia de las variables temporales y categóricas en las predicciones. Estos análisis también revelaron oportunidades para reducir la ventana de entrada temporal sin degradar significativamente el rendimiento, lo que podría reducir los requisitos computacionales.

A pesar de los bajos errores de predicción conseguidos, el rendimiento del modelo depende en gran medida de la calidad y la resolución temporal de los datos de entrada. Los conjuntos de datos incompletos o actualizados de forma irregular, así como la ausencia de variables contextuales como las condiciones meteorológicas, eventos especiales o incidentes de tráfico, pueden reducir la precisión.

El estudio de caso de Valencia aporta pruebas empíricas en un entorno europeo de datos abiertos en el que se está desplegando progresivamente una infraestructura de movilidad inteligente.

El trabajo futuro explorará estrategias de modelización híbridas que integren redes neuronales recurrentes con fuentes de datos externas para captar una gama más amplia de factores influyentes. Los enfoques de aprendizaje por transferencia también podrían facilitar el despliegue en ciudades con datos históricos limitados. Además, se llevarán a cabo evaluaciones reales del impacto del sistema en el comportamiento de los conductores y la movilidad urbana para perfeccionar tanto los modelos como sus aplicaciones prácticas.

A medio plazo, el sistema podría evolucionar hasta convertirse en un proceso automatizado de MLOps capaz de integrar nuevos datos en tiempo real, optimizar continuamente los parámetros del modelo y agilizar el despliegue en entornos de producción. Las técnicas y metodologías aquí desarrolladas son fácilmente extensibles a otros dominios de la movilidad y los servicios urbanos, ofreciendo una base escalable para futuras iniciativas de ciudades inteligentes.

7. Agradecimientos

El presente trabajo se ha desarrollado en el marco de la Cátedra financiada por el Ayuntamiento de Valencia: «Cátedra de Inteligencia Artificial y Visualización de Información para el Gobierno Abierto en la Ciudad de Valencia».

Referencias:

- Awan, F. M., Saleem, Y., Minerva, R., & Crespi, N. (2020). A comparative analysis of machine/deep learning models for parking space availability prediction. *Sensors*, 20(1), 322. <https://doi.org/10.3390/s20010322>
- Barraco, M., Bicocchi, N., Mamei, M., & Zambonelli, F. (2021). Forecasting parking lots availability: Analysis from a real-world deployment. *IEEE International Conference on Pervasive Computing and Communications Workshops* (pp. 299–304). IEEE. <https://doi.org/10.1109/PERCOMWORKSHOPS51409.2021.9430942>
- Batty, M., Axhausen, K. W., Giannotti, F., Pozdnoukhov, A., Bazzani, A., Wachowicz, M., Ouzounis, G., & Portugali, Y. (2012). Smart cities of the future. *The European Physical Journal Special Topics*, 214(1), 481–518. <https://doi.org/10.1140/epist/e2012-01703-3>
- Calabrese, F., Colonna, M., Lovisolo, P., Parata, D., & Ratti, C. (2011). Real-time urban monitoring using cell phones: A case study in Rome. *IEEE Transactions on Intelligent Transportation Systems*, 12(1), 141–151. <https://doi.org/10.1109/TITS.2010.2074196>
- Chen, G., Zhang, S., Weng, W., & Yang, W. (2023). Residual spatial-temporal graph convolutional neural network for on-street parking availability prediction. *International Journal of Sensor Networks*, 43(4), 246–257. <https://doi.org/10.1504/IJSNET.2023.135840>
- Cho, K., van Merriënboer, B., Bahdanau, D., & Bengio, Y. (2014). On the properties of neural machine translation: Encoder–decoder approaches. *Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation (SSST-8)* <https://doi.org/10.48550/arXiv.1409.1259>
- Hasan, S. (2020, 26 de junio). *Recurrent Neural Network and its variants*. Medium. <https://medium.com/@hasanshujaat4/recurrent-neural-network-and-its-variants-de75f9ee063>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Inam, S., Mahmood, A., Khatoon, S., Alshamari, M., & Nawaz, N. (2022). Multisource data integration and comparative analysis of machine learning models for on-street parking prediction. *Sustainability*, 14(12), 7317. <https://doi.org/10.3390/su14127317>
- Junta de Andalucía & Telefónica. (2021, julio). *Un sistema inteligente basado en Big Data permite conocer en tiempo real las plazas libres de aparcamiento en el PCT Cartuja*. APTE / PCT Cartuja. <https://www.apte.org/sistema-inteligente-basado-big-data-permite-conocer-tiempo-real-plazas-libres-aparcamiento-pct-cartu/>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774. <https://doi.org/10.48550/arXiv.1705.07874>
- Moreira-Matias, L., Gama, J., Ferreira, M., Mendes-Moreira, J., & Damas, L. (2013). Predicting taxi-passenger demand using streaming data. *IEEE Transactions on Intelligent Transportation Systems*, 14(3), 1393–1402. <https://doi.org/10.1109/TITS.2013.2262376>
- Moreno, D. (2021). *Predicting the use of car parks in the province of Barcelona* [Tesis doctoral, Universitat Pompeu Fabra]. UPF Repository. <http://hdl.handle.net/10230/49219>

- Pozo, R.F., González, A. B. R., Wilby, M. R., Vinagre Díaz, J. J., & Matesanz, M. V. (2022) Prediction of on-Street parking level of service based on random undersampling decision trees. *IEEE Transactions on Intelligent Transportation Systems*, 23(7), 8327-8336.
<https://doi.org/10.1109/TITS.2021.3077985>
- Sebatli, A., & Çavdur, F. (2023). Prediction of parking space availability using ARIMA and neural networks. *Endüstri Mühendisliği Dergisi*, 34(1), 86–108.
<https://doi.org/10.46465/endustrimuhendisligi.1241453>
- Shoup, D. C. (2005). *The high cost of free parking*. Planners Press, American Planning Association.
- Transformative Mobility SUTP. (2024). *Gestión de estacionamientos: Una contribución hacia la movilidad sostenible*. GIZ / SUTP. https://transformative-mobility.org/wp-content/uploads/2024/01/GIZ_SUTP_SB2c_Parking-Management_ES-2.pdf
- Vieta, G. L. (2024). *Modelos predictivos para ocupación de estacionamiento* [Trabajo Fin de Máster, Universidad de Sevilla]. idUS Repository. <https://hdl.handle.net/11441/161136>
- Yang, S., Ma, W., Pi, X., & Qian, S. (2019). 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*, 107, 248–265.
<https://doi.org/10.1016/j.trc.2019.08.010>
- Zhang, F., Shang, K., Yan, L., Nan, H., & Miao, Z. (2024). Prediction of parking space availability using improved MAT-LSTM network. *ISPRS International Journal of Geo-Information*, 13(5), 151.
<https://doi.org/10.3390/ijgi13050151>
- Zhao, X., & Zhang, M. (2024). Enhancing predictive models for on-street parking occupancy: Integrating adaptive GCN and GRU with household categories and POI factors. *Mathematics*, 12(18), 2823. <https://doi.org/10.3390/math12182823>
- Zheng, Y., Capra, L., Wolfson, O., & Yang, H. (2014). Urban computing: Concepts, methodologies, and applications. *ACM Transactions on Intelligent Systems and Technology*, 5(3), 1–55.
<https://doi.org/10.1145/2629592>
- Zheng, Y., Rajasegarar, S., & Leckie, C. (2015). Parking availability prediction for sensor-enabled car parks in smart cities. In *IEEE Tenth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)* (pp. 1–6). IEEE.
<https://doi.org/10.1109/ISSNIP.2015.7106955>