



Munich Personal RePEc Archive

Sustainable Urban Mobility: Demand Prediction with Artificial Intelligence

Gutierrez-Lythgoe, Antonio

April 2023

Online at <https://mpra.ub.uni-muenchen.de/117103/>
MPRA Paper No. 117103, posted 19 Apr 2023 07:20 UTC

Movilidad urbana sostenible: Predicción de demanda con Inteligencia Artificial

Antonio Gutiérrez-Lythgoe

Abril, 2023

Abstract

The evolution of cities has led to changes in urban mobility patterns, including an increased number of trips, longer and more dispersed routes. Therefore, it is crucial to study urban mobility efficiently to promote sustainability and well-being. In this context, we reviewed the existing literature on the applications of artificial intelligence (AI) in urban mobility research, specifically focusing on Deep Learning techniques such as CNN and LSTM models. These AI tools are being used to address the challenges of urban mobility research and offer new possibilities for tackling the pressing issues faced by cities, such as sustainability in transportation. AI can contribute to improving sustainability by predicting real-time traffic, optimizing transportation efficiency, and informing public policies that promote sustainable modes of transportation. In this study, we propose a Random Forest model for predicting demand for sustainable urban mobility based on machine learning, achieving accurate and consistent predictions. Overall, the application of AI in urban mobility research presents a unique opportunity to advance towards more sustainable, livable cities and resilient societies.

Resumen

La evolución de las ciudades ha generado cambios en los patrones de movilidad urbana, con un aumento en el número de viajes, trayectos más largos y dispersos. Para abordar estos desafíos, es importante utilizar de manera eficiente la inteligencia artificial (IA) en la investigación de la movilidad urbana. En este estudio se revisa la literatura existente sobre las aplicaciones de IA en este campo, destacando las técnicas basadas en Deep Learning, como los modelos de redes neuronales convolucionales (CNN) y de memoria a largo plazo (LSTM). Estas herramientas ofrecen nuevas posibilidades para abordar los desafíos actuales de las ciudades, especialmente en términos de sostenibilidad en el transporte urbano. Las técnicas de IA pueden contribuir a mejorar la sostenibilidad mediante la predicción del tráfico en tiempo real, la optimización de la eficiencia del transporte y el diseño de políticas públicas para fomentar modos de transporte más sostenibles. Además, se propone un modelo de predicción de demanda de movilidad urbana sostenible basado en Random Forest, con resultados prometedores en términos de precisión y consistencia.

Keywords: Artificial Intelligence, Urban mobility, Deep Learning, Machine Learning , sustainability

JEL Classification: R41, R42, C45, C53, Q56

1. Introducción

La Inteligencia Artificial (IA) está desarrollándose de manera disruptiva, posicionándose como un elemento crucial en el futuro inmediato (Acemoglu & Restrepo, 2020). La IA hace referencia a la capacidad de las máquinas de imitar el comportamiento humano inteligente para alcanzar objetivos en distintos entornos (Aghion et al., 2018). Esta tecnología se originó en la década de los 50 del siglo pasado como un campo de investigación emergente desde la informática (McCarthy et al., 2006; Turing, 2009). El objetivo principal de la IA era desarrollar sistemas que pudieran realizar tareas que requieren inteligencia humana, como la resolución de problemas, el aprendizaje, el reconocimiento de patrones y el razonamiento (Norvig, 2002). Los primeros trabajos que aplicaron IA se centraron en el desarrollo de sistemas de lógica simbólica, mediante la utilización de reglas y símbolos para representar el conocimiento y el razonamiento (Newell & Simon, 1956). Con el paso del tiempo, se desarrollaron nuevos enfoques para la IA, como el aprendizaje automático, que permite a las máquinas aprender de los datos sin ser programadas explícitamente (Domingos, 2012). En la década de 1990, el desarrollo de algoritmos de redes neuronales artificiales (ANN) permitió a los investigadores diseñar sistemas que pueden aprender de forma autónoma a partir de grandes cantidades de datos (Lecun et al., 2015). En la actualidad, la IA se ha convertido en una disciplina muy influyente en la informática, con aplicaciones en una amplia gama de campos, incluyendo la robótica, la visión por computadora, el procesamiento del lenguaje natural, la toma de decisiones y la automatización de tareas (Goodfellow et al., 2016).

A medida que la IA continúa evolucionando, su impacto en la economía y en el sistema productivo se vuelve cada vez más evidente. En particular, la IA tiene el potencial de transformar fundamentalmente la forma en que se producen y se distribuyen los bienes y servicios, así como de alterar la naturaleza del trabajo y el empleo en todo el mundo (Aghion et al., 2018; Acemoglu & Restrepo, 2020). En este sentido, algunos investigadores plantean el impacto que podría tener en el sistema productivo y sus posibles transformaciones de una economía de mercado hacia un sistema planificado (Cottrell & Cockshott, 1993; Lambert & Fegley, 2023). Este debate gira en torno a la idea de Mises de 1920 sobre el cálculo económico. Esta teoría afirma que los sistemas planificados son inviables porque el socialismo económico no dispone de la capacidad para calcular precios y valores de una manera efectiva, ya que no dispone de los elementos clave para ello, la propiedad privada y el mercado. La ausencia de tales elementos provoca

que la planificación de la economía sea ineficiente (von Mises, 2000). Algunos autores proponen que la IA pueda contribuir en este aspecto supliendo la función del mercado y la propiedad privada (Cottrell & Cockshott, 1993). En contraposición, Lambert & Fegley, (2023) afirman que la tecnología por sí sola no es un sustituto para el proceso de precios en el mercado. De este modo, los empresarios continuarán compitiendo por los factores de producción y la obtención de beneficios mediante la satisfacción del consumidor. La mayor dificultad a la que se enfrentarán, tanto las sociedades como las empresas, será aprovechar los beneficios de las tecnologías de IA, evitando, al mismo tiempo, el aumento del desempleo y la creciente desigualdad de riqueza (Makridakis, 2017).

En este contexto, la IA puede proporcionar soluciones para estudiar la movilidad en un entorno de cambios en la vida cotidiana.¹ Como señalan Akhavian & Behzadan (2016), con esta tecnología se pueden identificar patrones y tendencias en la actividad de los trabajadores, mejorando la eficiencia en la gestión del tiempo y los recursos en el entorno laboral. Por otro lado, la IA puede ayudar a comprender cómo las personas se mueven mediante la identificación de patrones de movilidad gracias a los datos de trayectorias geográficas (Gao et al., 2017). La aplicación de la Inteligencia Artificial en la investigación de patrones de movilidad urbana puede ser una herramienta valiosa para la promoción de la movilidad sostenible, necesaria debido al incremento de los desplazamientos en las ciudades, el desarrollo del transporte motorizado y el aumento del tamaño de la ciudad (Osorio-Arjona & García-Palomares, 2017).

En este artículo, se presenta una revisión de la literatura sobre la aplicación de la IA en el ámbito de la movilidad urbana, así como un análisis de sus implicaciones y las oportunidades que ofrece en el futuro de la investigación. En particular, aplicamos técnicas de aprendizaje automático sobre datos de sistemas de movilidad compartida para predecir la demanda de movilidad urbana sostenible.

En la Sección 2, detallamos algunas aplicaciones de Inteligencia Artificial, concretamente de Deep Learning, para estudiar el impacto que plantean estas técnicas sobre la investigación en movilidad urbana sostenible. En la Sección 3, se realiza una descripción de los datos empleados en el desarrollo de la aplicación de IA en este campo. En la

¹ La movilidad diaria de los individuos constituye un tema especialmente relevante desde el punto de vista del mercado laboral (Giménez et al., 2018, 2019c, 2020, 2022c, 2022d), desde la economía urbana y ambiental (Molina et al., 2020; Giménez et al., 2014, 2016, 2019a, 2019b, 2021, 2022a, 2022b; Echeverría et al., 2022a, 2023) y también desde la salud y el bienestar (Echeverría et al., 2022b)

Sección 4, detallamos la metodología aplicada para desarrollar el modelo de predicción de movilidad compartida. En la Sección 5 se exponen los resultados principales, así como las limitaciones y recomendaciones de política. Finalmente, en la Sección 6, se presenta la Conclusión.

2. Revisión de la literatura

En 1959, Arthur Samuel definió Machine Learning como un campo de estudio que proporciona capacidad de aprendizaje a las computadoras sin ser programado explícitamente (Samuel, 1959). En la actualidad podemos ampliar la definición de este concepto como un campo multidisciplinario que abarca una amplia gama de dominios de investigación que refuerzan su existencia (Alzubi et al., 2018). Este concepto es uno de los pilares fundamentales de la ciencia de datos junto con la estadística y el análisis de datos (Hayashi, 1998). Por este motivo, es imprescindible entender cómo funcionan estas técnicas y su aplicación al estudio del comportamiento de los individuos.

El modelo genérico de aprendizaje automático consta de seis componentes independientes del algoritmo adoptado, y se utiliza para resolver diversos problemas que requieren aprendizaje por parte de la máquina, tales como la identificación de patrones y relaciones en grandes conjuntos de datos, mejorando el rendimiento en una tarea específica a través de la ganancia de experiencia (Alzubi et al., 2018).

Una subcategoría del aprendizaje automático es Deep Learning. De acuerdo con Lecun et al. (2015), el Deep Learning es una técnica de IA enfocada en el aprendizaje de representaciones complejas de datos mediante múltiples capas de transformaciones no lineales. En lugar de requerir una programación detallada de las características, las técnicas de Deep Learning utilizan grandes cantidades de datos para aprender de forma autónoma y generar modelos precisos y útiles (Lecun et al., 2015). En resumen, es una herramienta muy útil para extraer patrones ocultos en los datos, que los economistas pueden utilizar para mejorar la comprensión y predicción de los fenómenos relacionados con la economía, como el teletrabajo y la movilidad.

Este concepto se enfoca en algoritmos que utilizan redes neuronales artificiales para aprender patrones y relaciones complejas en grandes conjuntos de datos (Lecun et al., 2015). Las redes neuronales artificiales que están diseñadas para imitar el funcionamiento del cerebro humano y se utilizan para resolver problemas de aprendizaje supervisado, no supervisado y por refuerzo. A diferencia del aprendizaje automático tradicional, que se

basa en algoritmos lineales, el Deep Learning utiliza múltiples capas de redes neuronales para extraer características y patrones de datos cada vez más complejos (Lecun et al., 2015; Alzubi et al., 2018).

2.1 Modo de transporte

Un ejemplo del valor de la Inteligencia Artificial en estudios de movilidad es su gran capacidad para detectar los modos de transporte utilizados por los individuos a partir de los datos existentes y recogidos de forma pasiva, como es el caso de los datos obtenidos por la actividad GPS (Wu et al., 2016). Gonzalez et al. (2010) demuestran que es posible determinar el modo de transporte utilizado por los individuos a través de los datos GPS recogido de forma pasiva a través de los teléfonos móviles aplicando redes neuronales. En sus resultados aciertan el 92,11% de los trayectos con vehículo privado (coche), el 81,58% de los trayectos en autobús y el 100% de los trayectos caminando. Yang et al., (2015), de la misma manera, aplican redes neuronales a los datos de GPS para detectar el modo de transporte empleado. En sus estimaciones la precisión de detección del modo de transporte es superior al 86%. Además, la precisión de detección del modo de autobús es mayor que en cualquier otro estudio. De la misma manera, Byon & Liang (2014), comparan el rendimiento de detección de modos de transporte utilizando redes neuronales entre los datos tradicionales de GPS y los datos recopilados por teléfono inteligente. Hay dos aspectos innovadores en este artículo: el primero es examinar el impacto de diferentes tasas de muestreo y duraciones de monitoreo en la precisión de detección de modos; el segundo es detectar modos de transporte en diferentes condiciones, como el escenario de horas pico versus el escenario sin horas pico, general versus específico de ruta y orientación fija versus sin orientación fija del teléfono inteligente.

Xiao, Juan, & Gao, (2015) llevaron a cabo un estudio en el que analizaron diferentes formas de identificar distintos tipos de viajes, como caminar, andar en bicicleta o tomar transporte público. En este artículo descubren que las redes neuronales son las más precisas en la detección del método de transporte. Sin embargo, con las redes neuronales tradicionales², es difícil obtener un buen resultado, ya que a menudo solo alcanzan un óptimo local. Para resolver esto, utilizaron una técnica llamada Optimización por Enjambre de Partículas

² Las Redes Neuronales Tradicionales son algoritmos que usan un conjunto de pesos y sesgos para hacer predicciones. Sin embargo, a menudo sólo pueden alcanzar un óptimo local cuando se entrenan con algoritmos de retropropagación. Particle Swarm Optimization (PSO) es un algoritmo alternativo que utiliza múltiples partículas para buscar la solución óptima global, lo que lo hace más preciso que las redes neuronales tradicionales.

(PSO en inglés) para tratar de obtener el mejor resultado posible. Luego, observaron cinco características diferentes para utilizar en el proceso de identificación, como la velocidad promedio, la velocidad media, la aceleración absoluta, entre otras. Sin embargo, la precisión para detectar viajes en autobús frente a la del automóvil no resultó óptima. Para mejorar este aspecto, aplican una característica conocida como tasa de puntos de baja velocidad³, y aplican la prueba de Kolmogorov-Smirnov de dos muestras para el contraste. Finalmente, dividen los datos en un conjunto de entrenamiento y un conjunto de prueba, observan que la precisión de la detección de modo en el conjunto de entrenamiento fue del 95.81% y la precisión de identificación del modo en el conjunto de prueba fue del 94.44%.

También encontramos otras metodologías de Inteligencia Artificial para detectar el modo de transporte utilizado, como Xiao, Juan, & Zhang (2015), estos autores utilizaron redes bayesianas para detectar modos basándose en datos GPS recopilados en una encuesta de viajes basada en un teléfono inteligente desde mediados de octubre de 2013 hasta mediados de julio de 2014. Indicaron que la mayoría de los métodos empleados para la detección del modo de viaje no describían la compleja relación entre las características seleccionadas como variables de entrada, y que la mayoría de estos estudios no utilizaban la matriz de confusión⁴ del clasificador inicial para mejorar sus clasificadores⁵. En el análisis, utilizaron el algoritmo K2 para establecer la estructura de las redes bayesianas y estimaron las correspondientes tablas de probabilidad condicional con métodos de máxima verosimilitud. Extrajeron cuatro características (la velocidad promedio, la velocidad del percentil 95%, la aceleración absoluta promedio y la distancia recorrida) para construir redes bayesianas que identificaran los modos de viaje. Basándose en la primera matriz de confusión en este documento, es posible hacer una mejor distinción entre los modos de bicicleta y e-bike, así como entre los modos de coche y autobús.

³ Se calcula dividiendo el número de puntos de velocidad baja (definidos como puntos con velocidades inferiores a 5 km/h) en un segmento, entre el número total de puntos en ese segmento. Esto permite estimar cuánto tiempo se dedicó a viajar a baja velocidad dentro de cada segmento, lo que luego se puede utilizar para diferenciar entre diferentes tipos de modos de viaje, como autobuses o automóviles.

⁴ Una matriz de confusión es una tabla que muestra el desempeño de un clasificador en términos de verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos. Puede ser utilizada para evaluar qué tan bien está funcionando el clasificador e identificar áreas donde necesita mejorarse.

⁵ Los clasificadores son algoritmos utilizados para clasificar datos en diferentes categorías. En este caso, el clasificador se utiliza para detectar qué modo de transporte estaba utilizando alguien en base a los datos de GPS recopilados de sus teléfonos inteligentes.

2.2 Predicción del tráfico

Otro gran campo de aplicación de la IA, concretamente Machine Learning al estudio de la movilidad es la predicción del volumen de congestión de las ciudades (Bogaerts et al., 2020). De acuerdo con Bogaerts et al. (2020), la predicción del tráfico se ha abordado desde cuatro perspectivas distintas: modelos estadísticos de series temporales, modelos de regresión supervisada, modelos de clasificación supervisada y modelos de reconocimiento de patrones-agrupamientos. Concretamente, en este apartado mencionamos algunas investigaciones que recurren a métodos de regresión supervisada, ya que hacen referencia a aquellas metodologías de aprendizaje automático (Angarita-Zapata et al., 2019). Es decir, mediante el enfoque de regresión supervisado podemos obtener una forma funcional a partir de un input de datos sin necesidad de establecer supuestos o consideraciones previas (Ermagun & Levinson, 2018). Lo cierto es que las técnicas de aprendizaje automático presentan ciertas ventajas - sobre otros métodos como podrían ser los modelos estadísticos de series temporales ARIMA - para identificar los patrones en el tráfico como la identificación de no linealidades (Bogaerts et al., 2020).

Duan et al. (2016) experimentan con un modelo de Deep Learning conocido como modelo de red neuronal LSTM para estimar el tiempo que dura un trayecto en vehículo particular en Inglaterra. Para ello utilizan los datos de Highways England, y construyen 66 redes neuronales LSTM de predicción de series. En la evaluación del modelo obtienen un error relativamente pequeño, del 7% en el conjunto de prueba. Du et al. (2018), proponen un método híbrido multimodal de Deep Learning para la predicción de flujo de tráfico a corto plazo, que permite el aprendizaje conjunto y adaptativo a las características de correlación espacio-temporal y las interdependencias temporales de los datos de tráfico de múltiples modalidades. Observan que el modelo es capaz de entender la predicción no lineal del tráfico urbano con precisión y eficacia. Hou & Edara (2018) proponen dos modelos basados en Deep Learning para predecir el tiempo dedicado al trayecto en las carreteras. En la evaluación del modelo, realizan estimaciones para la ciudad de Sant Louis, Missouri. Observan predicciones precisas tanto para condiciones de tráfico congestionado como no congestionado. Además, capta con éxito la dinámica del tráfico de incidentes inesperados o eventos especiales.

2.3 Predicción de demanda de transporte

De manera similar a la predicción del tráfico, las técnicas Deep Learning también pueden contribuir en la predicción de la demanda de transporte público o taxi en las ciudades (Wang et al., 2018). Esta aplicación constituye otra funcionalidad de la IA que permite dirigir la movilidad urbana hacia la gestión eficiente de los recursos (Ben-Akiva & Atherton, 1977). Generalmente, la literatura en estas técnicas ha considerado la relación espacial (por ejemplo, mediante el uso de CNN) o la relación temporal (por ejemplo, mediante el uso de LSTM) de manera independiente para la predicción de la demanda de transporte (Yao et al., 2018). La relación espacial se refiere a la relación entre diferentes ubicaciones en el espacio. En el contexto de la predicción del tráfico, esto podría referirse a la relación entre diferentes segmentos de carretera, intersecciones u otras características de la red vial. Una técnica común para modelar relaciones espaciales en la predicción del tráfico es el uso de redes neuronales convolucionales (CNN). Las CNN son un tipo de red neuronal que son especialmente buenas para procesar datos espaciales, como imágenes. En el contexto de la predicción del tráfico, una CNN podría tomar un mapa de la red vial y usarlo para predecir las condiciones de tráfico en diferentes ubicaciones. La relación temporal se refiere a la relación entre diferentes puntos en el tiempo. En el contexto de la predicción del tráfico, esto podría referirse a la relación entre las condiciones de tráfico en diferentes momentos del día, días de la semana o estaciones del año. Una técnica común para modelar relaciones temporales en la predicción del tráfico es el uso de redes neuronales de memoria a largo y corto plazo (LSTM). Las LSTMs son un tipo de red neuronal que son especialmente buenas para procesar datos secuenciales, como series temporales. En el contexto de la predicción del tráfico, una LSTM podría tomar una serie de datos históricos de tráfico y usarlos para predecir las condiciones de tráfico futuras.

Held et al. (2018) emplean datos demográficos y geográficos para predecir la demanda de movilidad en Suiza. En primer lugar, categorizan los datos de la población según sus preferencias de ruta diarias. Después, utilizan un método de aprendizaje supervisado llamado árbol de decisiones para clasificar los datos, y emplean una técnica de aprendizaje automático llamada Máquina de Vectores de Soporte⁶ (SVM) para extraer las características más importantes de los datos. El árbol de decisiones funciona mediante la

⁶ La Máquina de Vectores de Soporte (SVM, por sus siglas en inglés) es un algoritmo de aprendizaje automático supervisado utilizado para la clasificación y regresión de datos. SVM es capaz de clasificar conjuntos de datos en diferentes categorías al crear un hiperplano que separa los datos en diferentes clases.

utilización de numerosos árboles de decisiones independientes para crear un conjunto de árboles, y la precisión se incrementa al aumentar el número de árboles en el conjunto. Cada árbol clasifica los datos en función de sus atributos y el conjunto de árboles vota por la clasificación más común. Por otro lado, gracias al SVM clasifican los datos mediante la maximización de la separación entre las muestras. Posteriormente, utilizan algoritmos de aprendizaje automático para estimar la demanda futura en función de la distancia diaria recorrida por un vehículo. Yao et al. (2018) proponen un marco de red espacial-temporal de múltiples vistas profundas (DMVST-Net) para modelar tanto las relaciones espaciales como las temporales. Específicamente, el modelo propuesto consta de tres vistas: vista temporal (modelando las correlaciones entre los valores de demanda futura con puntos de tiempo cercanos a través de LSTM), vista espacial (modelando la correlación espacial local a través de CNN local) y vista semántica (modelando las correlaciones entre las regiones que comparten patrones temporales similares). Los resultados con datos de demanda real de taxis demuestran la eficacia de este enfoque sobre otros métodos empleados en la literatura.

Ye et al. (2019) aplican un nuevo método llamado CoST-Net para predecir la demanda de transporte tanto de taxis como de bicicletas compartidas. El método CoST-Net utiliza una red neuronal convolucional (CNN) para descomponer la demanda espacial en bases de demanda espacial ocultas, y luego una LSTM heterogénea para integrar los estados de las múltiples demandas de transporte y modelar su dinámica de manera mixta. Este método se enfoca en dos perspectivas: una micro y otra macro. Desde una perspectiva micro, se observa que la demanda espacial en un momento dado puede ser descompuesta en una combinación de varias bases de demanda espacial ocultas. Desde una perspectiva macro, se considera que las múltiples demandas de transporte están fuertemente correlacionadas tanto espacial como temporalmente. Los experimentos realizados con datos reales de demanda de taxi y bicicleta compartida demuestran que el método propuesto, CoST-Net, es superior a los métodos. Shu et al. (2020) propone un modelo efectivo para la predicción espacial-temporal de la demanda entre áreas de taxis a través de la integración de Redes Neuronales Convolucionales (CNN) y Memoria a Corto y Largo Plazo (LSTM). Se adopta CNN para extraer la correlación entre características y la dependencia temporal cercana, mientras que LSTM para fusionarlas en series temporales. Evalúan el modelo datos históricos de Haikou (China), los resultados

muestran que es más preciso y estable que el LSTM tradicional en este tipo de predicciones.

3. Datos

Para esta aplicación de IA en el estudio de movilidad urbana recurrimos a los datos históricos disponibles y utilizados en Fanaee-T & Gama (2014) (<https://archive.ics.uci.edu/ml/datasets/bike+sharing+dataset>). Estos datos provienen de un sistema de movilidad compartida sostenible de bicicletas. Los autores utilizan estos datos para detectar eventos que puedan afectar a la movilidad urbana utilizando técnicas de aprendizaje automático supervisado. Los sistemas de bicicletas compartidas constituyen la nueva generación de alquiler de bicicletas tradicional, donde todo el proceso desde la membresía, el alquiler y la devolución ha sido automatizado (Arias-Molinares et al., 2021). A través de estos sistemas, el usuario puede alquilar fácilmente una bicicleta desde una posición determinada y devolverla en otra posición. Hoy en día, existe un gran interés en estos sistemas debido a su importante papel en cuestiones de tráfico, medio ambiente y salud (García-Palomares et al., 2012; Arias-Molinares et al., 2021; Talavera-Garcia et al., 2021). Aparte de las interesantes aplicaciones del mundo real de los sistemas de bicicletas compartidas, las características de los datos generados por estos sistemas son muy atractivos para investigación. A diferencia de otros servicios de transporte, la duración del viaje, la posición de salida y llegada se registran explícitamente en estos sistemas. Esta característica convierte al sistema de bicicletas compartidas en una red de sensores virtual que se puede utilizar para detectar la movilidad en la ciudad (García-Palomares et al., 2012).

La base de datos empleada en este estudio es el conjunto de datos de alquiler de bicicletas compartidas de la ciudad de Washington D.C, llamado CBS. Este conjunto de datos contiene información diaria de alquiler de bicicletas por horas desde enero de 2011 hasta diciembre de 2012, con un total de 17,379 registros. Cada registro incluye información sobre la fecha, la hora, la temperatura, la humedad, la velocidad del viento, la sensación térmica, el número de bicicletas compartidas disponibles para alquilar, el número de bicicletas compartidas devueltas y el número total de bicicletas compartidas alquiladas. Podemos observar un análisis descriptivo para las variables continuas en la Tabla 1. La temperatura está normalizada y medida en grados celsius (dividida por 41, valor máximo). De la misma manera, la sensación térmica está normalizada y medida en grados celsius (dividida por 50). La velocidad del viento está normalizada, dividida por 67. La humedad

esta normalizada, dividida por 100. Para evitar problemas de tendencia, Fanaee-T & Gama (2014) seleccionan solo los datos correspondientes a los años 2011 y 2012.

4. Metodología

En esta aplicación, planteamos el desarrollo de un modelo de predicción de demanda de bicicletas por horas. Para ello, presentamos un método basado en el análisis de datos utilizando técnicas de aprendizaje automático para predecir la demanda horaria de bicicletas en la ciudad. Con este objetivo, preprocesamos los datos transformando las variables categóricas en numéricas para utilizarlas en el modelo de aprendizaje automático. Estas variables son las siguientes. La variable "weekday" que representa el día de la semana en siete categorías diferentes: domingo, lunes, martes, miércoles, jueves, viernes y sábado. La variable "weathersit" que representa el estado del clima en cuatro categorías diferentes: clima claro o parcialmente nublado, neblina o nubes y niebla, lluvia ligera o nieve, y lluvia intensa, granizo, tormenta y nieve con niebla. La variable "season" que representa la estación meteorológica en las siguientes categorías: primavera, verano, otoño e invierno. Creamos una variable dicotómica para cada categoría de manera que representamos con valor 1 si se cumple la condición expresada por la variable, 0 en caso contrario. También disponemos de una variable dicotómica que presenta valor 1 si el día es laborable y valor 0 si es festivo.

Para la estimación de la predicción, empleamos una técnica de regresión de bosques aleatorios (Random Forest) para entrenar el modelo de predicción. El método de Regresión de Bosques Aleatorios (Random Forest Regression) es un modelo de aprendizaje automático que se utiliza para predecir valores continuos (Breiman, 2001). Este modelo se basa en la creación de múltiples árboles de decisión, en los que se toman decisiones a partir de preguntas condicionales sobre las variables de entrada, de manera que la respuesta a cada pregunta divide el conjunto de datos en dos subconjuntos, que a su vez son divididos en dos subconjuntos adicionales a partir de nuevas preguntas condicionales, y así sucesivamente, hasta que se llega a una respuesta final.

Para aplicar el modelo de Random Forest, primeramente, seleccionamos las variables del conjunto al completo para construir los árboles de decisión. Esto se realiza para reducir la correlación entre los árboles y aumentar la diversidad del modelo. Seleccionadas las variables, construimos los árboles de decisión para la selección, que posteriormente son entrenados con una muestra aleatoria de los datos disponibles con reemplazo. En otras

palabras, un mismo dato puede aparecer varias veces en la muestra utilizada para entrenar el árbol. Una vez que se ha construido un árbol de decisión, se utiliza para hacer predicciones para nuevas instancias. Cada árbol de decisión utiliza el subconjunto de características correspondiente para hacer la predicción. La predicción final se obtiene combinando las predicciones de todos los árboles de decisión. En el caso de la regresión, se suele utilizar la media de las predicciones de todos los árboles.

La separación de los datos en conjuntos de entrenamiento y prueba es una técnica común en el aprendizaje automático para evaluar el rendimiento de un modelo. La idea es dividir el conjunto de datos en dos subconjuntos mutuamente excluyentes: uno para entrenar el modelo (conjunto de entrenamiento) y otro para evaluar el rendimiento del modelo entrenado (conjunto de prueba). En la implementación presentada, se utiliza la función *train_test_split()* de la librería *scikit-learn (sklearn)* en Python para dividir el conjunto de datos. Esta función toma tres argumentos principales: las características (condiciones ambientales y del calendario), la variable objetivo (demanda de bicicletas) que se utilizarán para entrenar el modelo, y el tamaño del conjunto de prueba como una fracción del tamaño total del conjunto de datos. En la aplicación presentada, utilizamos una fracción del 20% del conjunto de datos para el conjunto de prueba utilizando un valor del argumento *random_state=42* para fijar la semilla del generador de números aleatorios y obtener resultados reproducibles. La función devuelve cuatro subconjuntos de datos, de los que dos se utilizan para entrenar el modelo, y otros dos se utilizan para evaluar su rendimiento. Cada árbol decisión en el bosque se entrena en una muestra aleatoria del conjunto de entrenamiento y se utiliza para hacer una predicción individual. En este caso, se está utilizando la clase *RandomForestRegressor()* de la librería *scikit-learn* de Python para crear el modelo de bosques aleatorios. Se ha establecido un número de árboles de 100 y una profundidad máxima de 10 niveles para cada árbol. En otras palabras, creamos 100 árboles aleatorios y cada árbol se entrena para una profundidad máxima de 10 niveles.

5. Resultados

Como se puede observar en la Tabla 2, obtenemos los siguientes resultados. En la estimación realizada se obtuvo un error cuadrático medio de 8.89. Asimismo, el error absoluto obtenido fue de 1.28 y el error porcentual cuadrático mediano de 8.89. Estos resultados sugieren que el modelo es capaz de hacer predicciones precisas y consistentes. El hecho de que el error cuadrático medio y el error porcentual cuadrático mediano sean iguales constituyen un indicio de que el modelo no está sesgado y es capaz de ajustarse a

los datos de manera efectiva. Gráficamente, podemos observar la precisión del modelo en la Figura 1. Esto plantea que el modelo está proporcionando buenas estimaciones en relación con el valor medio de la demanda de bicicletas.

Además, se incluyeron variables relevantes en la estimación, como el día de la semana (weekday) que representa el día de la semana en siete categorías diferentes: domingo, lunes, martes, miércoles, jueves, viernes y sábado, la variable "weathersit" que representa el estado del clima en cuatro categorías diferentes: clima claro o parcialmente nublado, neblina o nubes y niebla, lluvia ligera o nieve, y lluvia intensa, granizo, tormenta y nieve con niebla, y la variable "season" que representa la estación meteorológica en las siguientes categorías: primavera, verano, otoño e invierno. Estas variables pueden ser importantes para capturar posibles variaciones temporales en la demanda de bicicletas compartidas.

Los resultados obtenidos en este estudio tienen implicaciones importantes para la toma de decisiones de política relacionadas con la gestión de sistemas de bicicletas compartidas. La capacidad del modelo de hacer predicciones precisas y consistentes, respaldada por los bajos valores de error cuadrático medio y error absoluto, sugiere que podría ser utilizado como una herramienta útil para predecir la demanda de bicicletas compartidas en diferentes condiciones climáticas y días de la semana. Estas predicciones precisas podrían ayudar a los operadores de sistemas de bicicletas compartidas a optimizar la asignación de bicicletas y estaciones, mejorando la eficiencia del sistema y brindando un mejor servicio a los usuarios. Además, la inclusión de variables como el día de la semana y el estado del clima en el modelo proporciona información adicional para la toma de decisiones en términos de estrategias de operación y promoción de los servicios de bicicletas compartidas en días específicos o en condiciones climáticas favorables.

No obstante, es importante tener en cuenta algunas limitaciones de este estudio. Aunque el modelo mostró un buen desempeño en la predicción de la demanda de bicicletas compartidas en general, es posible que su precisión varíe en diferentes momentos del día o en días de la semana con patrones de demanda atípicos. Además, aunque se incluyeron variables relevantes en el modelo, como el día de la semana y el estado del clima, puede haber otras variables importantes que no se consideraron en este estudio, como eventos especiales, festivos o características específicas de la ubicación de las estaciones de bicicletas compartidas. Por lo tanto, es necesario continuar evaluando y mejorando el

modelo a medida que se obtenga más información y datos. Asimismo, es importante considerar el contexto y las condiciones específicas del sistema de bicicletas compartidas en el que se aplique este modelo, ya que los resultados y las implicaciones de política pueden variar según las características y necesidades de cada sistema en particular.

6. Conclusión

La evolución de las ciudades ha provocado cambios en los patrones de movilidad urbana. Estos cambios se resumen en mayor número de viajes, trayectos más largos y de mayor dispersión. Por este motivo, es importante estudiar de manera eficiente la movilidad con el objetivo de conducir esta práctica hacia un escenario de mayor sostenibilidad y bienestar.

En este sentido, revisamos la literatura existente sobre las aplicaciones de IA en la investigación movilidad urbana. Exponemos técnicas de inteligencia artificial basadas en Deep Learning, en particular los modelos CNN y LSTM, que se están empleando para abordar los desafíos en la investigación de movilidad urbana. En conjunto, estas nuevas herramientas y técnicas de IA están abriendo un abanico de posibilidades para la investigación, lo que puede ayudar a abordar algunos de los desafíos más urgentes a los que se enfrentan las ciudades en la actualidad. Como se ha mencionado previamente, uno de estos desafíos es la sostenibilidad en el transporte urbano, la cual debe combatir una serie de riesgos, como la congestión del tráfico, la contaminación ambiental y/o la disminución de la calidad de vida de los ciudadanos.

Las técnicas de IA pueden ayudar a mejorar la sostenibilidad en el transporte urbano de diversas maneras. Por ejemplo, mediante la predicción del tráfico en tiempo real, se pueden tomar medidas para reducir la congestión y optimizar la eficiencia del transporte. Además, el análisis de los patrones de tráfico y de los comportamientos de movilidad de los ciudadanos contribuyen a diseñar políticas públicas que fomenten modos de transporte más sostenibles, como la bicicleta o el transporte público. En este contexto planteamos un modelo de Random Forest de predicción de demanda de movilidad urbana sostenible basado en aprendizaje automático. Los resultados de predicción señalan un error cuadrático medio de 8.89 y un error absoluto de 1.28. Estos resultados sugieren que disponemos de un modelo capaz de realizar predicciones precisas y consistentes. Además, la inclusión de variables relevantes como el día de la semana y el estado del clima en el

modelo proporciona información adicional para la toma de decisiones en términos de estrategias de operación y promoción de los servicios de bicicletas compartidas.

En definitiva, la aplicación de la IA en la investigación sobre movilidad urbana ofrece una oportunidad única para abordar los desafíos actuales y futuros de las ciudades. Al aprovechar estas nuevas herramientas y técnicas, podemos avanzar hacia un entorno urbano más sostenible, una ciudad más habitable y una sociedad más resiliente.

Referencias

- Acemoglu, D., & Restrepo, P. (2020). The wrong kind of AI? Artificial intelligence and the future of labour demand. *Cambridge Journal of Regions, Economy and Society*, 13(1), 25–35. <https://doi.org/10.1093/cjres/rsz022>
- Aghion, P., Jones, B. F., & Jones, C. I. (2018). Artificial intelligence and economic growth. In *The economics of artificial intelligence: An agenda* (pp. 237–282). University of Chicago Press.
- Akhavian, R., & Behzadan, A. H. (2016). Smartphone-based construction workers' activity recognition and classification. *Automation in Construction*, 71(Part 2), 198–209. <https://doi.org/10.1016/j.autcon.2016.08.015>
- Alzubi, J., Nayyar, A., & Kumar, A. (2018). Machine Learning from Theory to Algorithms: An Overview. *Journal of Physics: Conference Series*, 1142(1). <https://doi.org/10.1088/1742-6596/1142/1/012012>
- Angarita-Zapata, J. S., Masegosa, A. D., & Triguero, I. (2019). A Taxonomy of Traffic Forecasting Regression Problems from a Supervised Learning Perspective. *IEEE Access*, 7, 68185–68205. <https://doi.org/10.1109/ACCESS.2019.2917228>
- Arias-Molinares, D., Julio, R., García-Palomares, J. C., & Gutiérrez, J. (2021). Exploring micromobility services: Characteristics of station-based bike-sharing users and their relationship with dockless services. *Journal of Urban Mobility*, 1(October 2020), 100010. <https://doi.org/10.1016/j.urbmob.2021.100010>
- Ben-Akiva, M., & Atherton, T. J. (1977). Methodology for Short-Range Travel Demand Predictions: Analysis of Carpooling Incentives. *Journal of Transport Economics and Policy*, 11(3), 224–261. <http://www.jstor.org/stable/20052477>
- Bogaerts, T., Masegosa, A. D., Angarita-Zapata, J. S., Onieva, E., & Hellinckx, P. (2020). A graph CNN-LSTM neural network for short and long-term traffic forecasting based on trajectory data. *Transportation Research Part C: Emerging Technologies*, 112, 62–77. <https://doi.org/10.1016/j.trc.2020.01.010>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32.
- Byon, Y.-J., & Liang, S. (2014). Real-time transportation mode detection using smartphones and artificial neural networks: Performance comparisons between smartphones and conventional global positioning system sensors. *Journal of Intelligent Transportation Systems*, 18(3), 264–272.
- Cottrell, A., & Cockshott, W. P. (1993). Calculation, complexity and planning: the socialist calculation debate once again. *Review of Political Economy*, 5(1), 73–112.
- Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78–87.
- Du, S., Li, T., Gong, X., & Horng, S.-J. (2018). A hybrid method for traffic flow forecasting using multimodal deep learning. *ArXiv Preprint ArXiv:1803.02099*.
- Duan, Y., Lv, Y., & Wang, F. Y. (2016). Travel time prediction with LSTM neural network. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, 1053–1058. <https://doi.org/10.1109/ITSC.2016.7795686>

- Echeverría, L., Giménez-Nadal, J.I. and Molina, J.A. (2022a). Who uses green mobility? Exploring profiles in developed countries. *Transportation Research Part A: Policy and Practice*, 163, 247-265. <https://doi.org/10.1016/j.tra.2022.07.008>.
- Echeverría, L., Giménez-Nadal, J.I. and Molina, J.A. (2022b). Green mobility and well-being. *Ecological Economics*, 195, 107368. <https://doi.org/10.1016/j.ecolecon.2022.107368>.
- Echeverría, L., Giménez-Nadal, J.I. and Molina, J.A. (2023). Citizen security and urban commuting in Latin America. *Urban Studies*, forthcoming. <https://doi.org/10.1177/00420980231158035>.
- Ermagun, A., & Levinson, D. (2018). Spatiotemporal traffic forecasting: review and proposed directions. *Transport Reviews*, 38(6), 786–814. <https://doi.org/10.1080/01441647.2018.1442887>
- Fanaee-T, H., & Gama, J. (2014). Event labeling combining ensemble detectors and background knowledge. *Progress in Artificial Intelligence*, 2(2–3), 113–127. <https://doi.org/10.1007/s13748-013-0040-3>
- Gao, Q., Zhou, F., Zhang, K., Trajcevski, G., Luo, X., & Zhang, F. (2017). *Identifying Human Mobility via Trajectory Embeddings*. www.datatang.com/data/44139
- García-Palomares, J. C., Gutiérrez, J., & Latorre, M. (2012). Optimizing the location of stations in bike-sharing programs: A GIS approach. *Applied Geography*, 35(1–2), 235–246. <https://doi.org/10.1016/j.apgeog.2012.07.002>
- Giménez, J.I. and Molina, J.A. (2014). Commuting time and labour supply in the Netherlands: a time use study. *Journal of Transport Economics and Policy*, 48 (3), 409-426.
- Giménez, J.I. and Molina, J.A. (2016). Commuting time and household responsibilities: evidence using propensity score matching. *Journal of Regional Science*, 56, 332-359. <https://doi.org/10.1111/jors.12243>.
- Giménez-Nadal, J.I. and Molina, J.A. (2019a). Green commuting and gasoline taxes in the United States. *Energy Policy*, 132, 324-331. <https://doi.org/10.1016/j.enpol.2019.05.048>.
- Giménez-Nadal, J.I. and Molina, J.A. (2019b). Modeling commuting time in the US: Bootstrapping techniques to avoid overfitting. *Papers in Regional Science*, 98(4), 1667-1684. <https://doi.org/10.1111/pirs.12424>.
- Giménez-Nadal, J.I. and Molina, J.A. (2019c). Daily feelings of US workers and commuting time. *Journal of Transport & Health*, 12, 21-33. <https://doi.org/10.1016/j.jth.2018.11.001>.
- Giménez-Nadal, J.I., Molina, J.A. and Velilla, J. (2020). Commuting and self-employment in Western Europe. *Journal of Transport Geography*, 88, 102856. <https://doi.org/10.1016/j.trangeo.2020.102856>.
- Giménez-Nadal, J.I., Molina, J.A. and Velilla, J. (2021). Two-way commuting: Asymmetries from time use surveys. *Journal of Transport Geography*, 95, 103146. <https://doi.org/10.1016/j.trangeo.2021.103146>.
- Giménez-Nadal, J.I., Molina, J.A. and Velilla, J. (2022a). Increasing the use of public bicycles: efficiency and demand. *Economic Analysis and Policy*, 76, 745-754. <https://doi.org/10.1016/j.eap.2022.09.015>.

- Giménez-Nadal, J.I., Molina, J.A. and Velilla, J. (2022b). The daily mobility of older adults: Urban/rural differences in ten developed countries. *The Annals of Regional Science*, forthcoming. <https://doi.org/10.1007/s00168-022-01192-0>.
- Gimenez-Nadal, J. I., Molina, J. A., & Velilla, J. (2022). Commuting time and sickness absence of US workers. *Empirica*, 49(3), 691-719.
- Gonzalez, P. A., Weinstein, J. S., Barbeau, S. J., Labrador, M. A., Winters, P. L., Georggi, N. L., & Perez, R. (2010). Automating mode detection for travel behaviour analysis by using global positioning systems-enabled mobile phones and neural networks. *IET Intelligent Transport Systems*, 4(1), 37–49. <https://doi.org/10.1049/iet-its.2009.0029>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Hayashi, C. (1998). What is data science? Fundamental concepts and a heuristic example. *Data Science, Classification, and Related Methods: Proceedings of the Fifth Conference of the International Federation of Classification Societies (IFCS-96), Kobe, Japan, March 27–30, 1996*, 40–51.
- Held, M., Küng, L., Çabukoglu, E., Pareschi, G., Georges, G., & Boulouchos, K. (2018). Future mobility demand estimation based on sociodemographic information: A data-driven approach using machine learning algorithms. *18th Swiss Transport Research Conference (STRC 2018)*.
- Hou, Y., & Edara, P. (2018). Network Scale Travel Time Prediction using Deep Learning. *Transportation Research Record*, 2672(45), 115–123. <https://doi.org/10.1177/0361198118776139>
- Lambert, K. J., & Fegley, T. (2023). Economic Calculation in Light of Advances in Big Data and Artificial Intelligence. *Journal of Economic Behavior and Organization*, 206, 243–250. <https://doi.org/10.1016/j.jebo.2022.12.009>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. In *Nature* (Vol. 521, Issue 7553, pp. 436–444). Nature Publishing Group. <https://doi.org/10.1038/nature14539>
- Makridakis, S. (2017). The forthcoming Artificial Intelligence (AI) revolution: Its impact on society and firms. In *Futures* (Vol. 90, pp. 46–60). Elsevier Ltd. <https://doi.org/10.1016/j.futures.2017.03.006>
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI Magazine*, 27(4), 12.
- Molina, J.A., Giménez-Nadal, J.I. and Velilla, J. (2020). Sustainable commuting: Results from a social approach and international evidence on carpooling. *Sustainability*, 12(22), 9587. <https://doi.org/10.3390/su12229587>.
- Newell, A., & Simon, H. (1956). The logic theory machine--A complex information processing system. *IRE Transactions on Information Theory*, 2(3), 61–79.
- Norvig, P. R. (2002). A modern approach. *Prentice Hall Upper Saddle River, NJ, USA: Rani, M., Nayak, R., & Vyas, OP (2015). An Ontology-Based Adaptive Personalized e-Learning System, Assisted by Software Agents on Cloud Storage. Knowledge-Based Systems*, 90, 33–48.

- Osorio-Arjona, J., & García-Palomares, J. C. (2017). Nuevas fuentes y retos para el estudio de la movilidad urbana. *Cuadernos Geográficos*, 56(3), 247–267. <https://doi.org/10.30827/CUADGEO.V56I3.5352>
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3(3), 210–229.
- Shu, P., Sun, Y., Zhao, Y., & Xu, G. (2020). Spatial-temporal taxi demand prediction using LSTM-CNN. *2020 IEEE 16th International Conference on Automation Science and Engineering (CASE)*, 1226–1230.
- Talavera-Garcia, R., Romanillos, G., & Arias-Molinares, D. (2021). Examining spatio-temporal mobility patterns of bike-sharing systems: the case of BiciMAD (Madrid). *Journal of Maps*, 17(1), 7–13. <https://doi.org/10.1080/17445647.2020.1866697>
- Turing, A. M. (2009). *Computing machinery and intelligence*. Springer.
- von Mises, L. (2000). The equations of mathematical economics and the problem of economic calculation in a socialist state. *The Quarterly Journal of Austrian Economics*, 3(1), 27–32.
- Wang, D., Yang, Y., & Ning, S. (2018). DeepSTCL: A Deep Spatio-temporal ConvLSTM for Travel Demand Prediction. *2018 International Joint Conference on Neural Networks (IJCNN)*, 1–8. <https://doi.org/10.1109/IJCNN.2018.8489530>
- Xiao, G., Juan, Z., & Gao, J. (2015). Travel mode detection based on neural networks and particle swarm optimization. *Information*, 6(3), 522–535.
- Xiao, G., Juan, Z., & Zhang, C. (2015). Travel mode detection based on GPS track data and Bayesian networks. *Computers, Environment and Urban Systems*, 54, 14–22. <https://doi.org/https://doi.org/10.1016/j.compenvurbsys.2015.05.005>
- Yang, F., Yao, Z., & Jin, P. J. (2015). GPS and acceleration data in multimode trip data recognition based on wavelet transform modulus maximum algorithm. *Transportation Research Record*, 2526(1), 90–98.
- Yao, H., Wu, F., Ke, J., Tang, X., Jia, Y., Lu, S., Gong, P., Ye, J., & Li, Z. (2018). *Deep Multi-View Spatial-Temporal Network for Taxi Demand Prediction*. <http://arxiv.org/abs/1802.08714>
- Ye, J., Sun, L., Du, B., Fu, Y., Tong, X., & Xiong, H. (2019). Co-Prediction of Multiple Transportation Demands Based on Deep Spatio-Temporal Neural Network. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 305–313. <https://doi.org/10.1145/3292500.3330887>

Tabla 1. Estadística descriptiva para la muestra de bicicletas compartidas.

Variables	Mean	Sd
Temperature	0,497	0,193
Feeling temperature	0,476	0,172
Humidity	0,627	0,193
Wind speed	0,190	0,122
Casual users	35,676	49,305
Registered users	153,787	151,357
Total rented bikes	189,463	181,388

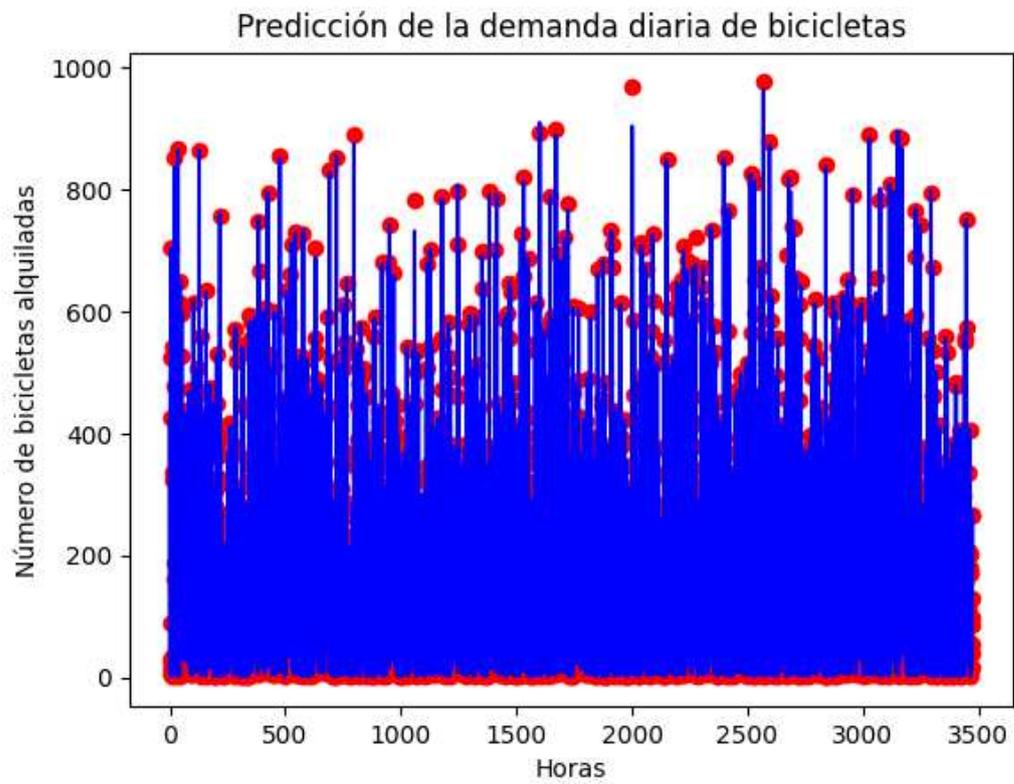
Nota: La temperatura está normalizada y medida en grados celsius (dividida por 41, valor máximo). La sensación térmica está normalizada y medida en celsius (dividida por 50). La velocidad del viento está normalizada, dividida por 67. La humedad esta normalizada, dividida por 100.

Tabla 7. Bondad de ajuste de la predicción para el modelo Random Forest

Error cuadrático medio	0,497
Error absoluto medio	0,476
Error porcentual cuadrático mediano	0,627

Nota: Resultados para las predicciones realizadas por el método de Random Forest con 100 arboles y 10 niveles de profundidad

Figura 1. Valores reales vs valores estimados de la demanda de bicicletas por horas.



Nota: Histórico y predicción de bicicletas alquiladas por horas en la muestra de prueba (3500 horas). Los puntos rojos hacen referencia a los valores reales y las barras azules a los valores estimados.