

Comparación de modelos de predicción para estimar la demanda de viajes en radio taxis.

Comparison of prediction models to estimate travel demand in radio taxis.

Diego Chamorro Andrade¹ , Nadia Nathaly Sánchez Pozo¹ 

¹ Universidad Politécnica Estatal del Carchi, Posgrado. Tulcán, 040101, Ecuador.

Enviado: 2024-03-25, Aceptado: 2024-11-06, Publicado: 2026-01-30

Autor de correspondencia:

Nadia Sánchez: nadia.sanchez@upec.edu.ec

DOI: [10.53358/ideas.v8i1.1080](https://doi.org/10.53358/ideas.v8i1.1080)



PALABRAS CLAVE

Modelos predictivos,
movilidad urbana,
pronóstico,
servicios de taxi,
aprendizaje automático,
demanda de viajes,
modelización predictiva.

RESUMEN

El sector de servicios de radiotaxi enfrenta constantemente el reto de gestionar la demanda variable de viajes, lo que subraya la importancia de utilizar modelos predictivos para optimizar recursos y mejorar la calidad del servicio. Este artículo realiza un análisis comparativo entre tres modelos de pronóstico de series temporales: ARIMA, Prophet y Random Forest. Para llevar a cabo el estudio, se utilizó el entorno de desarrollo *RStudio* con el lenguaje de programación *R*. Las medidas de evaluación empleadas incluyen el Error Absoluto Medio (MAE), el Error Cuadrático Medio (MSE) y la Raíz del Error Cuadrático Medio (RMSE), seleccionadas por su capacidad para proporcionar una evaluación robusta del desempeño de los modelos. Los resultados indican que el modelo ARIMA supera significativamente a los otros modelos, exhibiendo un MAE de 1.46, MSE de 4.71 y RMSE de 2.17, lo que demuestra una precisión superior en sus predicciones. En comparación, los modelos Prophet (MAE: 2.83, MSE: 14.62, RMSE: 3.82) y Random Forest (MAE: 3.27, MSE: 17.03, RMSE: 4.12) presentaron mayores errores. Este análisis resalta la eficacia del modelo ARIMA en el pronóstico de la demanda de viajes en servicios de radiotaxi, proporcionando información valiosa para mejorar la planificación y la eficiencia operativa.

KEYWORDS

Predictive models,
forecast,
taxi services,
travel demand,
urban mobility,
machine learning,
predictive modeling.

ABSTRACT

The taxi service industry consistently grapples with the challenge of managing fluctuating travel demand. To optimize resource allocation and enhance service quality, predictive modeling has become a crucial tool. This study conducts a comparative analysis of three time series forecasting models: ARIMA, Prophet, and Random Forest. The *R* programming language within the *RStudio* environment was utilized to implement the models. To evaluate model performance, we employed robust metrics including Mean Absolute Error (MAE), Mean Squared Error (MSE), and Root Mean Squared Error (RMSE). The findings reveal that the ARIMA model significantly outperforms its counterparts. With an MAE of 1.46, MSE of 4.71, and RMSE of 2.17, ARIMA demonstrated superior accuracy in forecasting travel demand. In contrast, Prophet (MAE: 2.83, MSE: 14.62, RMSE: 3.82) and Random Forest (MAE: 3.27, MSE: 17.03, RMSE: 4.12) exhibited higher error rates. This analysis underscores the effectiveness of ARIMA in predicting travel demand within the taxi service industry, providing valuable insights for improved operational planning and efficiency.

1. Introducción

En la actualidad, la movilidad urbana y el transporte eficiente y adaptable constituyen un componente fundamental para el funcionamiento dinámico de las ciudades [1]. Dentro de este contexto, los servicios de Radio Taxi han emergido como una opción de movilidad clave, brindando acceso flexible y directo a los usuarios [2]. Sin embargo, la optimización de estos servicios se ve estrechamente ligada con la capacidad de anticipar y satisfacer la demanda de viajes de manera precisa y oportuna [3].

Existen tres tipos principales de mercados de taxis: de clasificación, de tránsito y prerreservados. Los mercados de clasificación son eficientes en el uso de recursos, pero pueden ser incómodos para los usuarios. Los mercados de tránsito son menos eficientes y generan más contaminación. Los mercados prerreservados son seguros y confiables, pero pueden ser más caros. Las aplicaciones colaborativas o tecnológicas han experimentado un auge en los últimos años, brindando una serie de ventajas sobre los modelos tradicionales [4].

El servicio de taxi es una parte importante del transporte público en todo el mundo. Sin embargo, a menudo se enfrenta a desafíos, como la falta de cobertura en áreas de difícil acceso. En el estudio de [5] se encontró que el servicio de taxi en Perú es deficiente en áreas rurales y periurbanas. Los autores señalan que esto se debe a que las empresas de taxi no consideran rentable operar en estas áreas.

En [6] también se destaca la importancia de la cobertura del servicio de taxi. Los autores señalan que los diferentes segmentos de la población tienen necesidades distintas, y que el servicio debe adaptarse a estas necesidades.

La demanda de viajes en el servicio de Radio Taxi, por su complejidad y dinamismo, se convierte en un fenómeno multifacético, influenciado por múltiples elementos, como la hora del día, el día de la semana y la ubicación geográfica. La capacidad de predecir la demanda de viajes con precisión puede ayudar a mejorar la eficiencia y la sostenibilidad del transporte público.

Este trabajo realiza un análisis comparativo de técnicas estocásticas y heurísticas para pronosticar la demanda de viajes en el servicio de Radio Taxi de la Cooperativa Rápido Nacional, ubicada en la ciudad de Tulcán-Ecuador. El enfoque integra técnicas avanzadas de análisis de datos con el objetivo de modelar series temporales, con especial énfasis en la utilización de modelos ARIMA (*Autoregressive Integrated Moving Average*) y modelos de *machine learning* reconocidos por su eficacia en la predicción de tendencias en datos temporales. La importancia de este estudio radica en su potencial para mejorar la eficiencia operativa y la planificación de recursos en servicios de radio taxi, un sector que enfrenta desafíos constantes debido a la variabilidad en la demanda de viajes.

El propósito principal de este trabajo es comparar la precisión de diversos modelos predictivos en la estimación de la demanda de viajes, proporcionando así una base sólida para la toma de decisiones estratégicas en la gestión de servicios de transporte. Este estudio contribuye a la literatura existente al ofrecer un análisis detallado y actualizado de modelos predictivos aplicados a la industria del transporte en la ciudad de Tulcán, destacando la relevancia de técnicas avanzadas en la mejora del servicio al cliente y la optimización de operaciones. El estudio se divide en cinco secciones principales. La Sección 2 abarca una revisión exhaustiva de la literatura existente. La Sección 3 especifica los materiales y métodos empleados en la investigación. En las Secciones 4 y 5 se exponen los resultados alcanzados y se extraen conclusiones del análisis de datos, junto con una discusión sobre las implicaciones derivadas de estos resultados.

2. Revisión de la bibliografía

El pronóstico de la demanda de taxis ha sido estudiado por un amplio número de investigadores utilizando una variedad de métodos cuantitativos y cualitativos, examinando diferentes escenarios en los que se prestan dichos servicios [7]. En un estudio reciente, [8] desarrollaron un modelo novedoso para pronosticar la demanda de taxis, el cual utiliza la influencia del barrio a través de un aprendizaje conjunto.

Por su parte, [9] destacan la importancia crítica de la predicción precisa de la demanda, identificando disparidades significativas en la disponibilidad de taxis entre distintos sectores urbanos. Este estudio asocia la demanda de servicios de taxi y Uber con ubicaciones específicas, empleando algoritmos avanzados como LSTM (*Long Short-Term Memory*), una red neuronal de aprendizaje profundo, y modelos de series temporales como ARIMA. Los resultados indican la superioridad del modelo LSTM en zonas con demanda impredecible debido a su habilidad para descubrir patrones no lineales complejos, aportando una alta predictibilidad y una fuerte correlación con la movilidad humana.

En un contexto similar, [10] destacan la viabilidad de pronosticar el comportamiento de los usuarios de taxis en Dubái empleando modelos predictivos basados en la ubicación y el tiempo. Al comparar modelos de series temporales como ARIMA y SARIMA, ARIMA presenta un menor error y una precisión del 74.8 % en la predicción de la demanda. El análisis revela la ausencia de tendencias y estacionalidad en la serie temporal, aunque se identifica un patrón

estacional diario. Los datos procesados del sistema de taxis permiten identificar nodos con alta generación de viajes y destinos frecuentes, como centros comerciales y zonas de negocios, información valiosa para optimizar rutas de autobuses y atraer a usuarios de taxis hacia servicios de transporte público [10].

El estudio de [11] emplea el modelo automático ARIMA para realizar un análisis de series temporales con el fin de predecir las áreas de mayor afluencia de pasajeros, basándose en datos espacio-temporales proporcionados por una empresa local de taxis en Bandung. Por otra parte, [12] realizaron una contribución importante al enfrentar la disparidad entre la oferta y la demanda en los servicios de transporte público mediante el diseño y la implementación de un sistema de transporte inteligente. El estudio se centró en pronosticar la demanda en tiempo real de servicios de taxi en línea, evaluando seis modelos basados en redes neuronales de retropropagación (BPNN) y en el algoritmo de refuerzo de gradiente extremo (XGB) para predecir la demanda de taxis en línea. La investigación hizo hincapié en la correlación entre la demanda de taxis terrestres y la demanda de taxis en línea, presentando un modelo de pronóstico en tiempo real de la demanda de taxis en línea considerando la demanda proyectada de taxis [12].

En [2] se exploró la aplicación de modelos de aprendizaje automático para pronosticar el tiempo de permanencia dentro de un vehículo entre dos ubicaciones, utilizando trazas históricas de taxis en Nueva York (NYC). El estudio integró datos de taxis con el conjunto de datos de Uber y seleccionó variables semánticas mediante detección de valores atípicos y selección de características basada en puntajes de Chi-cuadrado. Se comparó la eficacia de tres métodos: Regresión de Árbol de Decisión, Random Forest Prediction y Regresión de vecinos más cercanos (*K-Nearest Neighbor*) en la predicción de la duración del viaje.

En [13] se estudió el pronóstico de la demanda de servicios de movilidad aérea urbana (UAM) en diferentes momentos del día y en diversas regiones geográficas de Nueva York. El estudio empleó variables relacionadas con los viajes y las condiciones climáticas como predictores para cuatro modelos populares de *machine learning* (ML): regresión logística, redes neuronales artificiales, bosques aleatorios y aumento de gradiente. Los resultados experimentales favorecieron consistentemente al modelo de aumento de gradiente, al proporcionar un rendimiento de predicción superior, destacándose ubicaciones específicas, períodos de tiempo y días de la semana como predictores críticos.

La aplicación de modelos ML para pronosticar la demanda de taxis involucra un análisis minucioso de diversos factores, como la hora del día, las regiones geográficas, las variables del viaje y las condiciones climáticas [14]. Además, se han implementado técnicas avanzadas de estudio de series temporales, incluyendo modelos ARIMA, Prophet de Facebook y Random Forest Prediction, para evaluar su eficacia en el pronóstico de la demanda futura [9].

3. Materiales y Métodos

Para el desarrollo de este trabajo se ha adaptado la metodología KDD (*Knowledge Discovery in Databases*), también conocida como Descubrimiento de Conocimiento en Bases de Datos o minería de datos [15]. Esta elección se justifica por las siguientes razones: la metodología KDD proporciona un marco de trabajo claro y organizado, además de un enfoque centrado en los datos. KDD enfatiza la importancia del preprocesamiento y la preparación de datos para obtener resultados confiables y puede aplicarse en diversos ámbitos. Por otra parte, promueve la evaluación y validación de los modelos obtenidos para garantizar su robustez y generalización. Además, requiere la intervención de expertos que guíen el proceso e interpreten los resultados, lo cual es fundamental para la comparación y evaluación de algoritmos de pronóstico.

El proceso de KDD consta de varias etapas interrelacionadas, y para el desarrollo de esta investigación se han definido las siguientes: recolección y preprocesamiento de datos, selección y aplicación de modelos predictivos, evaluación del desempeño de los modelos y análisis comparativo. Para el análisis de los datos se utilizó el lenguaje de programación *R* en el entorno de desarrollo integrado *RStudio*. Se emplearon las siguientes librerías: *tidyverse* para la manipulación de datos, *forecast* para los modelos ARIMA, *prophet* para el modelo de Facebook y *randomForest* para el modelo de bosque aleatorio.

Para evaluar la eficacia de estos modelos se calcularon métricas de rendimiento, como el MAE, MSE y RMSE. Estos análisis se orientaron a determinar cuál de los modelos ofrece la mejor capacidad de predicción en el contexto específico de la demanda de taxis. La Figura 1 muestra la metodología adoptada.

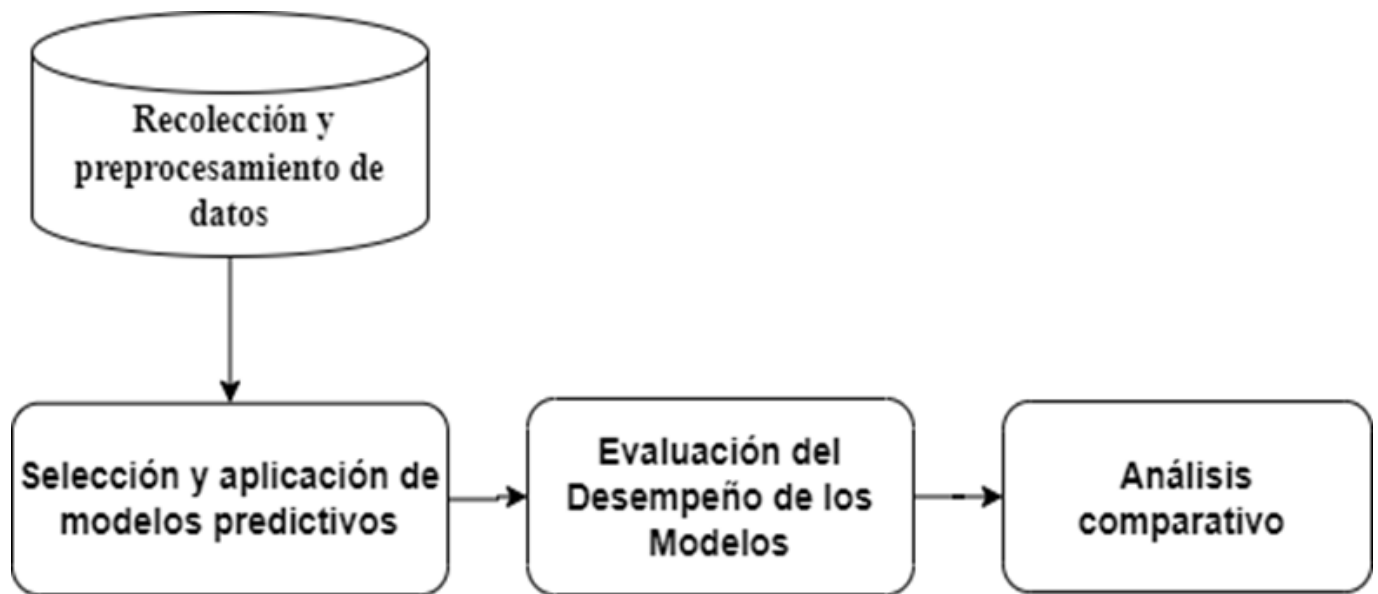


Figura 1: Metodología estudio comparativo de modelos predictivos de servicios de radio taxi

3.1. Datos

Se recopilaron datos históricos de la demanda de viajes del servicio de Radio Taxi de la Cooperativa Rápido Nacional, abarcando el período del 2 de enero de 2022 al 2 de enero de 2023. Los datos se almacenaron en una hoja de cálculo en formato Excel, que contenía un total de 68 278 registros distribuidos en siete columnas. Las variables incluidas en la base de datos fueron: fecha, hora, dirección de origen, unidad vehicular, dirección de destino, tiempo de respuesta y operador de radio.

Este conjunto de datos, que cubre la actividad de cuatro operadores de radio y 68 unidades vehiculares, proporcionó una base amplia para el análisis de la demanda de servicios de transporte en diferentes áreas geográficas de la ciudad. A partir de los totales diarios de servicios, se construyó una serie temporal con 366 registros, correspondiente a cada día del año.

Para evaluar y validar la capacidad predictiva de los modelos utilizados, la serie temporal se dividió en dos conjuntos: un conjunto de entrenamiento que abarcó el 80 % de los datos (292 días) y un conjunto de prueba que comprendió el 20 % restante (74 días). Esta división estratégica es fundamental para la validación del modelo, permitiendo evaluar su desempeño predictivo sobre datos no vistos durante el entrenamiento. La Figura 2 ilustra esta serie temporal, destacando en azul los datos de entrenamiento y en rojo los datos de prueba.

La base de datos original fue sometida a un riguroso proceso de limpieza debido a la presencia de valores faltantes y errores ortográficos en las variables de direcciones de origen y destino. Este proceso integral incluyó una etapa crucial de caracterización para mejorar la integridad y la calidad de los datos. En esta fase, se realizó un análisis de la ubicación geográfica, que consistió en dividir la ciudad en tres zonas principales: sur, centro y norte, utilizando como referencia el plano de Unidades Territoriales Urbanas (UTU).

Esta estrategia de caracterización fue fundamental, puesto que las ubicaciones individuales presentaban incoherencias y carecían de una representatividad completa. Al asociar cada ubicación con una de las zonas definidas, se logró una segmentación significativa y cohesiva de los datos, lo que permitió una comprensión más precisa de los patrones de solicitud de servicios en diferentes áreas geográficas de la ciudad.




Figura 2: Serie temporal de servicios de radio taxi

3.2. Modelos predictivos

Autoregressive Integrated Moving Average (ARIMA)

Los modelos ARIMA son herramientas ampliamente reconocidas en el estudio de series temporales, utilizadas para modelar y prever patrones en datos temporales, como la demanda de taxis. El modelo ARIMA combina elementos de autorregresión (AR), integración (I) y promedio móvil (MA) para capturar la autocorrelación, estacionalidad y tendencias en los datos [16]. Se representa como $ARIMA(p, d, q)$, donde p representa la cantidad de términos autorregresivos, d indica el número de diferenciaciones no estacionales y q corresponde al número de errores de pronóstico rezagados. La elección precisa de estos parámetros proporciona una estructura adaptable y eficaz para analizar y predecir datos temporales, eliminando tendencias y capturando las complejidades de la serie temporal [11].

Prophet

El modelo *Prophet*, desarrollado por Facebook, representa una innovación en el campo de estudio de series temporales, demostrando su eficacia en la predicción de datos temporales caracterizados por patrones estacionales y tendencias anuales. Su capacidad para gestionar de manera efectiva eventos especiales, feriados y adaptarse a cambios en el comportamiento del usuario lo convierte en una opción altamente atractiva para el pronóstico de la demanda del servicio de taxi, especialmente en entornos urbanos dinámicos.

Este modelo se distingue por su capacidad intrínseca para manejar la complejidad inherente a los datos temporales, incorporando de manera automática eventos relevantes y adaptándose dinámicamente a las variaciones en el comportamiento temporal [17]. En el contexto específico de la predicción de la demanda de taxis, Prophet ofrece una solución robusta para la identificación de patrones estacionales y tendencias anuales, abordando de manera proactiva la inclusión de factores externos que podrían influir significativamente en la demanda, como feriados y otros eventos [18].

Prophet es descrito por la Ecuación 1, la cual representa el crecimiento en series temporales de una manera adaptable a diferentes patrones de cambio. Se estructura como una función a tramos, lo que significa que puede seguir un patrón de crecimiento lineal o logístico, capturando así cambios no periódicos [19].

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (1)$$

Por otro lado, $s(t)$ describe cambios repetitivos que siguen un patrón periódico, como la estacionalidad que puede ocurrir semanal o anualmente. Además, $h(t)$ representa los efectos de las vacaciones u otros eventos especiales que

pueden tener horarios irregulares. Finalmente, el término ε_t se refiere al error en el modelo, capturando cualquier cambio o variación inusual que no sea explicado por las funciones anteriores [19]. La capacidad de adaptación y la consideración precisa de múltiples variables hacen de Prophet una herramienta robusta para la planificación y optimización en entornos urbanos dinámicos, donde la demanda de taxis puede estar sujeta a fluctuaciones rápidas y cambios en el comportamiento del usuario.

Random Forest

Random Forest es un modelo de *machine learning* basado en ensamblaje que sobresale por su capacidad para operar conjuntos de datos complejos y capturar patrones no lineales. En lugar de depender de un solo modelo predictivo, utiliza múltiples árboles de decisión entrenados de manera independiente en subconjuntos aleatorios del conjunto de datos. La predicción final se determina mediante la combinación de las salidas de estos árboles, lo que aprovecha la diversidad de enfoques [20].

Este algoritmo es particularmente eficaz en el pronóstico de la demanda en contextos como los servicios de taxi, donde los factores pueden ser diversos y presentar relaciones no lineales. Además, Random Forest ofrece robustez al tratar con sobreajustes y es resistente al ruido en los datos, asegurando una generalización sólida a nuevos conjuntos de datos. Su naturaleza de ensamblaje proporciona estabilidad, mitigando sesgos individuales y mejorando la precisión general [21].

3.3. Métricas de evaluación

Métricas de evaluación

En este estudio comparativo de modelos, se utilizan métricas clave como el Error Cuadrático Medio (RMSE), el Error Absoluto Medio (MAE) y el Error Cuadrático Medio (MSE), las cuales son fundamentales para evaluar la precisión de los modelos analizados. Estas métricas desempeñan un papel crucial al proporcionar una evaluación cuantitativa y comparativa de la capacidad predictiva de cada modelo.

En las fórmulas que se presentarán a continuación, la notación se refiere a la serie real, mientras que la notación representa la serie pronosticada. Estas expresiones matemáticas ofrecen una base objetiva para la evaluación de la discrepancia entre los pronósticos generados por los modelos y los datos reales de la serie temporal, contribuyendo así a un análisis riguroso de su desempeño comparativo [12].

Error Absoluto Medio (MAE)

El Error Absoluto Medio es el promedio de la diferencia absoluta entre los valores observados y predichos. Es una métrica lineal, lo que significa que todos los errores se ponderan por igual. Además, tiende a ser menos sensible a valores atípicos en comparación con el error cuadrático medio. Sus gradientes con respecto a las predicciones pueden tomar valores de +1 o -1 [22].

$$MAE = \frac{1}{n} \sum |y_j - \hat{y}_j| \quad (2)$$

Raíz del Error Cuadrático Medio (RMSE)

Determina la diferencia entre el valor predicho por el modelo y el valor real.

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (3)$$

Error Cuadrático Medio (MSE)

Calcula el error cuadrático medio, entre la predicción y el valor real

$$MSE = \frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2 \quad (4)$$

3.4. Selección de modelos predictivos

Se seleccionaron los modelos ARIMA, Prophet y Random Forest debido a sus características complementarias. ARIMA es un modelo clásico para series temporales y es adecuado para capturar patrones estacionales y tendencias. Prophet, por su parte, es una herramienta robusta para modelar series temporales con cambios estructurales y estacionalidad compleja. Finalmente, Random Forest, como algoritmo de aprendizaje automático, puede capturar patrones no lineales y es útil para manejar series temporales con múltiples factores influyentes. Los parámetros de los modelos ARIMA se seleccionaron utilizando el criterio de información de Akaike (AIC). Para Prophet y Random Forest, se

realizó una búsqueda aleatoria de hiperparámetros con el objetivo de encontrar la combinación que minimizara el error de predicción en un conjunto de validación.

4. Resultados

Para determinar el comportamiento de la demanda en cada una de las zonas se calcula el número de servicios en origen y destino. Donde se puede evidenciar que la mayor dinámica del transporte de pasajeros en taxis se encuentra concentrada en el centro de la ciudad de Tulcán. Lo que concuerda con el progreso urbanístico de la ciudad, en la parte central se ubican instituciones financieras, servicios públicos e instituciones educativas, entre otros.

La Tabla 1 presenta la distribución de la demanda origen-destino en función de las zonas urbanas.

Tabla 1: Demanda Origen-Destino en función de zonas urbanas

| Zona | Origen | Destino |
|---------------------------|--------------|--------------|
| Centro | 39240 | 40154 |
| Norte | 12253 | 16743 |
| Sur | 16785 | 11381 |
| Total de servicios | 68278 | 68278 |

4.1. Evaluación del desempeño de los modelos

4.1.1. Resultados modelo ARIMA

Se realizó un análisis estadístico de la serie temporal para evaluar sus componentes, tales como la tendencia y la estacionalidad. Los resultados del análisis indicaron que la serie temporal es no estacionaria, lo que significa que la media y la varianza de la serie cambian con el tiempo. Para corregir la no estacionariedad, se empleó un modelo ARIMA (2,0,2) con diferenciación regular y estacional.

El modelo ARIMA (2,0,2) con diferenciación regular y estacional es un modelo que tiene en cuenta la tendencia y la estacionalidad de la serie temporal. El número de términos autorregresivos (p) es 2, lo que indica que el modelo utiliza dos variables pasadas para predecir el valor actual de la serie. El número de términos de media móvil (q) es 2, lo que indica que el modelo utiliza dos variables de error pasadas para predecir el valor actual de la serie. El orden de diferenciación no estacional (d) es 0.

El número de veces que la serie temporal se diferencia estacionalmente (D) es 1, lo que indica que la serie temporal tiene un período estacional de 12. Lo que da como resultado un modelo SARIMA (ARIMA estacional)

Los parámetros del modelo fueron seleccionados mediante máxima verosimilitud, señalando una tendencia constante y un patrón estacional aditivo. El rendimiento se evaluó utilizando métricas como el Error Cuadrático Medio (MSE), que resultó relativamente bajo, demostrando la capacidad del modelo para predecir con precisión los valores de la serie temporal.

El análisis de los errores revela un Error Absoluto Medio (MAE) de 1.46, un MSE de 4.71 y RMSE de 2.17. Estos resultados indican que el modelo ha capturado eficazmente la estructura subyacente de la serie temporal, respaldado por un criterio de información de Akaike (AIC) de 332.89 (Figura 3), lo que sugiere estabilidad en el modelo.

```
Series: d_test
ARIMA(2,0,2)(2,1,0)[12]

Coefficients:
ar1      ar2      ma1      ma2      sar1      sar2
0.0323   0.0955   0.1205   0.2761  -0.6120  -0.2442
s.e.    0.4234   0.3950   0.3997   0.3849   0.1512   0.1551

sigma^2 = 6.061:  log likelihood = -159.45
AIC = 332.89    AICc = 334.73    BIC = 348.53

[1] "MAE: -1.45936531913804"
[1] "MSE: -4.71446215429224"
[1] "RMSE: -2.17128122413755"
```

Figura 3: Resultados del modelo ARIMA

En la Figura 4 pronóstico modelo ARIMA, se aprecia un solapamiento inicial entre las series real y proyectada en los primeros días, lo que sugiere que el modelo ha logrado capturar de manera efectiva la tendencia original de la serie temporal. Este solapamiento inicial indica que las predicciones del modelo están en línea con las observaciones reales en el período inicial de la serie. En resumen, el modelo ha destacado su capacidad para anticipar la tendencia general y la estacionalidad de la serie temporal.




Figura 4: Pronóstico modelo ARIMA y datos de prueba

4.1.2. Resultados modelo Prophet

Se realizó una búsqueda aleatoria de hiperparámetros utilizando random search para identificar la combinación óptima que minimizara el error cuadrático medio sobre un conjunto de validación independiente. En este caso, la configuración empleada es la siguiente:

- Daily seasonality=TRUE: Esto permite al modelo capturar mejor las tendencias y variaciones a lo largo del día.
- Changepoint_prior_scale = 3: Este hiperparámetro controla la flexibilidad del modelo para adaptarse a cambios en la tendencia. Un valor de 3 indica una flexibilidad moderada, permitiendo al modelo ajustarse a cambios en la serie temporal.
- Seasonality_mode = adaptive: El modo de estacionalidad adaptativa es una elección inteligente, ya que permite al modelo ajustar automáticamente si la estacionalidad es aditiva o multiplicativa.
- Seasonality_prior_scale = 5: Este hiperparámetro ajusta la fuerza de la estacionalidad. Un valor de 5 indica que se está permitiendo cierta influencia de la estacionalidad en las predicciones, permitiendo una adaptación más sensible a las variaciones temporales.

La Figura 5 representa la predicción del modelo Prophet junto con los valores reales de la serie temporal. La predicción es capaz de capturar los valores picos de la serie en algunas ocasiones, lo que indica que el modelo es capaz de capturar las tendencias de la serie temporal. Además, la Figura 6 muestra que los días con mayor demanda son los lunes y viernes. Este resultado es coherente con las expectativas, puesto que son días laborables, lo que suele conllevar una mayor demanda de servicios.




Figura 5: Pronóstico modelo Prophet y datos de prueba




Figura 6: Comportamiento semanal modelo Prophet

Se evaluaron las métricas de predicción con el conjunto de prueba y el conjunto predicho, el valor MAE fue igual a 2.83, indica que, en promedio, las predicciones difieren alrededor de 2.83 unidades del valor real. Este valor es relativamente bajo, demostrando que el modelo tiene un buen rendimiento en términos de precisión.

Además, el MSE de 14.63 revela que existen variabilidades significativas en las predicciones, siendo más grandes los errores cuadráticos promedio. Por otra parte, el valor RMSE de 3.82, ofrece una perspectiva intuitiva de la dispersión de los errores. Un valor de 3.82 revela que los pronósticos difieren, en promedio, alrededor de 3.82 unidades de los valores reales. En general, los resultados de los errores son positivos. Prophet tiene un buen rendimiento en términos de precisión, aunque podría mejorar en términos de variabilidad.

4.1.3. Resultados modelo Random forest

Para optimizar el modelo de bosque aleatorio, se realizó una búsqueda exhaustiva de hiperparámetros utilizando grid search. Se variaron los siguientes parámetros: número de árboles entre 50 y 200, profundidad máxima entre 3 y 10, criterio de división (Gini o entropía), y número de variables aleatorias consideradas en cada división. Se evaluó el desempeño de cada combinación de hiperparámetros utilizando el error cuadrático medio en un conjunto de validación independiente. La configuración óptima seleccionada fue: 100 árboles, profundidad máxima de 5, criterio de división Gini y un tercio de las variables consideradas en cada división. Esta configuración permitió obtener un modelo con un buen equilibrio entre sesgo y varianza.

En el análisis del modelo Random Forest, se utilizaron diferentes métricas para evaluar su desempeño. Los resultados obtenidos fueron los siguientes: el Error Absoluto Medio (MAE) fue de 3.28, el Error Cuadrático Medio (MSE) fue de 17.02, y RMSE fue de 4.13.

En cuanto a los hiperparámetros del modelo, se configuraron con un número de árboles (ntree) igual a 100, una profundidad máxima (max_depth) de 10 y un tamaño mínimo de nodo hoja (min_node_size) de 8.

Para este modelo en la Figura 7, se visualiza que el algoritmo logra una precisión notable al pronosticar los valores al final de la serie temporal. Este aspecto muestra una capacidad significativa del modelo para anticipar los patrones en la última fase de la serie. Además, se observa que las predicciones siguen la tendencia general de la serie original, lo que sugiere que el modelo ha capturado adecuadamente la estructura subyacente de los datos. Sin embargo, se identifica una discrepancia en la amplitud en el eje vertical (servicios), indicando que, aunque los coeficientes de error son bajos, existen variaciones en la magnitud de las estimaciones.




Figura 7: Pronóstico modelo Random Forest y datos de prueba

4.2. Análisis comparativo

El análisis comparativo de los modelos de pronóstico destaca a ARIMA como la opción óptima para prever la demanda de viajes en servicios de radio taxi, como se detalla en la Tabla 2 coeficientes de error de los modelos predictivos.

Tabla 2: Coeficientes de error de los modelos predictivos

| Modelos | MAE | MSE | RMSE |
|---------------|------|-------|------|
| ARIMA | 1.46 | 4.71 | 2.17 |
| Prophet | 2.83 | 14.62 | 3.82 |
| Random forest | 3.27 | 17.03 | 4.12 |

Los coeficientes de error de los tres modelos. Demuestran que ARIMA exhibe el menor Error Medio Absoluto (MAE) de 1.46, indicando que, en promedio, las predicciones difieren apenas 1.46 unidades del valor real. Además, presenta un rendimiento notable en términos de variabilidad, lo que sugiere que las predicciones están cercanas a los valores reales.

Comparativamente, el modelo Prophet muestra un rendimiento ligeramente inferior en precisión, con un MAE de 2.83, pero destaca en estabilidad, evidenciado por un MSE de 14.63 y un RMSE de 3.82. En contraste, el modelo Random Forest presenta un rendimiento menos preciso, con un MAE de 3.28, aunque exhibe mayor estabilidad con un MSE de 17.02 y un RMSE de 4.13.




Figura 8: Comparación de métricas de error de los modelos predictivos

Los resultados generales respaldan la elección de ARIMA como la mejor alternativa para predecir la demanda de viajes en servicios de radio taxi, como se refleja en la Figura 9. La precisión y estabilidad de ARIMA lo convierten en una herramienta valiosa para la predicción de la demanda de servicios de radio taxi de la cooperativa Rápido Nacional, permitiendo una asignación eficiente de recursos, como vehículos y conductores, así como la identificación de oportunidades estratégicas, como la expansión a nuevas áreas o la introducción de servicios adicionales.




Figura 9: Servicios de radio taxi serie original y pronósticos

Discusión de resultados

Los resultados obtenidos en este estudio son consistentes con investigaciones previas que han utilizado modelos ARIMA para predecir la demanda de transporte. Sin embargo, a diferencia de [23], donde se encontró que Random Forest superaba a ARIMA en series de tiempo con alta frecuencia, nuestros resultados muestran un mejor desempeño de ARIMA. Esta diferencia podría deberse a las características específicas de nuestros datos, como una menor variabilidad estacional y una tendencia más lineal. Además, la inclusión de variables explicativas adicionales en el modelo Random Forest podría mejorar su precisión, tal como se ha demostrado en [24]. Sin embargo, en nuestro caso, ARIMA resultó ser el modelo más adecuado para capturar los patrones subyacentes de la demanda de viajes en radio taxi.

El análisis comparativo de los modelos de pronóstico resalta a ARIMA como la opción óptima para prever la demanda de viajes en servicios de radio taxi, un hallazgo consistente con estudios previos que han identificado a ARIMA como una herramienta eficaz en la predicción de series temporales en contextos similares. Por ejemplo, investigaciones realizadas por [11] han demostrado la efectividad de los modelos ARIMA en situaciones donde los patrones de datos son estacionales y tienen componentes de tendencia bien definidos.

En comparación, el modelo Prophet, aunque menos preciso que ARIMA, ofrece una estabilidad destacable en sus predicciones. Este modelo es reconocido por su capacidad para manejar series temporales con fuertes efectos estacionales y días festivos, lo que lo hace adecuado para datos con variaciones significativas a lo largo del tiempo [25].

El rendimiento del modelo Random Forest, si bien es menos preciso en términos de MAE, MSE y RMSE, sigue siendo una alternativa viable para escenarios donde la facilidad de implementación y la capacidad de manejar datos de alta dimensionalidad son importantes. [26] resalta la robustez de este método para la predicción en contextos con múltiples variables predictoras.

Los resultados generales del estudio, ilustrados en las Figuras 8 y 9, refuerzan la elección de ARIMA como la mejor alternativa para la predicción de la demanda de servicios de radio taxi de la cooperativa Rápido Nacional. Su precisión y estabilidad lo convierten en una herramienta invaluable para optimizar la asignación de recursos, como vehículos y conductores, y para identificar oportunidades estratégicas, como la expansión a nuevas áreas geográficas o la introducción de servicios adicionales.

5. Conclusiones y trabajo futuro

En este artículo, se ha evaluado el desempeño de tres modelos predictivos (ARIMA, Prophet y Random Forest) en la predicción de la demanda de viajes en servicios de radio taxi. Los resultados del análisis indican que el modelo ARIMA se destaca como la mejor opción, mostrando el menor Error Medio Absoluto (MAE) y un buen rendimiento en términos de variabilidad, lo que sugiere que sus predicciones son precisas y estables en comparación con los otros modelos, como se observa en la Figura 9. Este modelo se presenta como una elección idónea para empresas de radio taxi

que buscan anticipar tanto tendencias como variaciones diarias en la demanda, permitiendo la planificación eficiente de la asignación de recursos y la identificación de oportunidades de crecimiento.

Por otro lado, los resultados sugieren que el modelo Prophet también es una opción viable para predecir la demanda de viajes en servicios de radio taxi. Aunque su precisión es ligeramente inferior a la de ARIMA, como lo demuestran los valores de MAE descritos en la Tabla 2, Prophet demuestra un mejor rendimiento en términos de variabilidad, ofreciendo predicciones más estables, aunque potencialmente menos precisas que las del modelo ARIMA.

El modelo Random Forest, por su parte, exhibe un rendimiento inferior tanto en términos de precisión como de variabilidad en comparación con ARIMA y Prophet. A pesar de ello, podría ser una opción adecuada para empresas que buscan un modelo de predicción rápido y fácil de implementar, aunque con predicciones potencialmente menos precisas y estables que los otros dos modelos evaluados.

La principal limitación de este estudio radica en su enfoque en una sola ciudad. Para trabajos futuros, se recomienda extender la investigación a múltiples localidades para evaluar la robustez de los modelos. Además, investigar técnicas más avanzadas de *machine learning*, como redes neuronales o modelos *ensemble*, para mejorar aún más la precisión y estabilidad de las predicciones. Por otra parte, sería beneficioso explorar el impacto de factores externos, como condiciones climáticas y eventos locales, en la demanda de viajes. Otro aspecto importante es el desarrollo de estrategias para la implementación en tiempo real de estos modelos predictivos, integrándolos en sistemas de gestión de flotas para optimizar la asignación de recursos de manera dinámica.

Referencias

- [1] R. Arteaga-Sánchez, M. Belda-Ruiz, A. Ros-Galvez, and A. Rosa-Garcia, "Why continue sharing: Determinants of behavior in ridesharing services," *International Journal of Market Research*, vol. 62, no. 6, pp. 725–742, 2020.
- [2] B. Roy and D. Rout, "Predicting taxi travel time using machine learning techniques considering weekend and holidays," in *Advances in Computing and Data Sciences*, 2022, pp. 258–267.
- [3] G. S. Bauer, A. Phadke, J. B. Greenblatt, and D. Rajagopal, "Electrifying urban ridesourcing fleets at no added cost through efficient use of charging infrastructure," *Transportation Research Part C*, vol. 105, pp. 385–404, 2019.
- [4] T. Lyu, P. Wang, Y. Gao, and Y. Wang, "Research on the big data of traditional taxi and online car-hailing: A systematic review," *Journal of Traffic and Transportation Engineering*, vol. 8, no. 1, pp. 1–34, 2021.
- [5] V. Cuevas, M. Estrada, and J. M. Salanova, "Management of on-demand transport services in urban contexts. barcelona case study," *Transportation Research Procedia*, vol. 13, pp. 155–165, 2016.
- [6] J. Aarhaug and K. Skollerud, "Taxi: Different solutions in different segments," *Transportation Research Procedia*, vol. 1, no. 1, pp. 276–283, 2014.
- [7] R. Goyal, C. Reiche, C. Fernando, and A. Cohen, "Advanced air mobility: Demand analysis and market potential of the airport shuttle and air taxi markets," *Sustainability*, vol. 13, no. 13, p. 7421, 2021.
- [8] A. Thakur and D. S. Monga, "Taxi demand forecasting utilizing neighbourhood influence based on ensemble learning," *International Journal for Research in Applied Science and Engineering Technology*, vol. 10, no. 5, pp. 894–900, 2022.
- [9] K. Zhao, D. Khryashchev, and H. Vo, "Predicting taxi and uber demand in cities: Approaching the limit of predictability," *IEEE Transactions on Knowledge and Data Engineering*, vol. 33, no. 6, pp. 2723–2736, 2021.
- [10] M. Odeh, "Taxi trips prediction and bus capacity coverage analysis," 2020.
- [11] M. S. Jamil and S. Akbar, "Taxi passenger hotspot prediction using automatic arima model," in *ICSITech*, 2017, pp. 23–28.
- [12] Z. Liu, H. Chen, X. Sun, and H. Chen, "Data-driven real-time online taxi-hailing demand forecasting based on machine learning method," *Applied Sciences*, vol. 10, no. 19, p. 6681, 2020.
- [13] S. Rajendran, S. Srinivas, and T. Grimshaw, "Predicting demand for air taxi urban aviation services using machine learning algorithms," *Journal of Air Transport Management*, vol. 92, p. 102043, 2021.

- [14] S.-H. Choi and M.-K. Han, “The empirical evaluation of models predicting bike sharing demand,” in *ICTC*, 2020, pp. 1560–1562.
- [15] B. R. Pérez-Gutiérrez, “Comparación de técnicas de minería de datos para identificar indicios de deserción estudiantil,” *Revista UIS Ingenierías*, vol. 19, no. 1, pp. 193–204, 2020.
- [16] L. I. Pérez, P. C. Millán, V. I. L. de Sabando, and P. Casares, “Impacto de los shocks externos en el transporte aéreo,” *Anales ASEPUMA*, vol. 28, p. 6, 2020.
- [17] A. Maltas, H. Ozen, and A. Saracoglu, “Methodology to detect bus stop influence zones utilizing facebook prophet changepoint detection method,” *KSCE Journal of Civil Engineering*, vol. 27, no. 10, pp. 4472–4484, 2023.
- [18] S. Rashidibajgan and T. Hupperich, “Improving the performance of opportunistic networks using machine learning techniques,” *Journal of Sensor and Actuator Networks*, vol. 11, no. 4, p. 61, 2022.
- [19] J. López, “Análisis de series de tiempo pronóstico de demanda de uso de aeropuertos en argentina,” 2018.
- [20] M. e. a. Aghaabbasi, “Predicting the use frequency of ride-sourcing by off-campus university students,” *Transportation Research Part A*, vol. 136, pp. 262–281, 2020.
- [21] S. e. a. Salcedo-Sanz, “Analysis, characterization, prediction, and attribution of extreme atmospheric events,” *Theoretical and Applied Climatology*, 2023.
- [22] X. Li, H. Wang, P. Sun, and H. Zu, “Spatiotemporal features—extracted travel time prediction leveraging gcn,” *Sustainability*, vol. 13, no. 3, p. 1253, 2021.
- [23] J. e. a. Liu, “Short-term forecasting of emerging on-demand ride services,” in *ICTIS*, 2017, pp. 489–495.
- [24] M. M. Ibrahim and F. S. Mubarek, “Improving prediction for taxi demand by using machine learning,” in *DeSE*, 2023, pp. 451–456.
- [25] S. J. Taylor and B. Letham, “Business time series forecasting at scale,” *PeerJ Preprints*, 2017.
- [26] X. Yan, X. Liu, and X. Zhao, “Using machine learning for direct demand modeling of ridesourcing services in chicago,” *Journal of Transport Geography*, vol. 83, p. 102661, 2020.