



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY



FACULTAD DE
INGENIERÍA

Estado del Arte

Estado del Arte presentado por

Nicolás Escobar, Leonela Pereira

en cumplimiento parcial de los requerimientos para la graduación de la carrera
de Ingeniería en Computación de Facultad de Ingeniería de la Universidad de la
República

Supervisores

Libertad Tansini
Pedro Piñeyro, Carlos Testuri

Montevideo, 4 de abril de 2025



Estado del Arte por Nicolás Escobar, Leonela Pereira tiene licencia [CC Atribución - No Comercial - Sin Derivadas 4.0](https://creativecommons.org/licenses/by-nc-nd/4.0/).

Índice general

1. Introducción	1
1.1. Introducción	1
1.2. Revisión Sistemática	3
1.2.1. Formulación del string de búsqueda	3
1.2.2. Criterios de exclusión	4
1.2.3. Categorización de artículos	6
2. Factores, Datos y Horizontes de Predicción	11
2.1. Factores que afectan el tiempo de viaje	11
2.2. Recopilación y procesamiento de datos	14
2.3. Horizontes de predicción	18
3. Modelos de Predicción de Tiempos de Viaje	21
3.1. Modelos ingenuos	21
3.1.1. Predictores instantáneos	21
3.1.2. Predictores históricos	22
3.1.3. Predictores híbridos	23
3.2. Modelos basados en la teoría del tráfico	23
3.2.1. Modelos microscópicos	23
3.2.2. Modelos macroscópicos	23
3.3. Modelos basados en datos	24
3.3.1. Modelos estadísticos	25
3.3.2. Modelos de aprendizaje automático	26
3.3.3. Modelos de aprendizaje profundo	32
4. Clasificación de Predicción de Tiempos de Viaje	39
4.1. Clasificación según el tipo de vehículo	39
4.1.1. Vehículo particular	39
4.1.2. Taxi y ride-hailing	40
4.1.3. Transporte público colectivo	41
4.2. Clasificación según el entorno	43
4.2.1. Autopistas	43
4.2.2. Entorno urbano	45

5. Enfoques para Resolver la Predicción del Tiempo de Viaje	47
5.1. Enfoques basados en ruta	48
5.2. Enfoques basados en OD	49
6. Conclusiones	51
Referencias	53
A. Anexo A. Revisión Sistemática	59
A.1. Buscador Springer Link	60
A.2. Buscador Science Direct	61
A.3. Buscadores Scopus y IEEE Xplore	62
B. Anexo B. Siglas	63

Capítulo 1

Introducción

1.1. Introducción

De acuerdo con un reporte de las Naciones Unidas, en el 2018 la población urbana constituía aproximadamente el 55 % de la población mundial, equivalente a unos 4.2 billones de personas, y se prevé que para el 2050 esta cifra ascienda al 2/3 de la población global (Ou, 2022; Chughtai, Haq, y Muneeb, 2022; Lee, Choo, Choi, y Lee, 2022). La rápida urbanización trae consigo una serie de oportunidades, así como nuevos desafíos. Entre estos se encuentra el desafío de abordar la congestión, entendida como la condición en la que más del 50 % de los registros tienen una velocidad vehicular inferior a 20 kilómetros por hora para un segmento de carretera dado (Fang, Liu, Chen, y Hwang, 2022).

La congestión se ha convertido en un problema crítico en muchas ciudades, repercutiendo en la vida de las personas, en la productividad laboral y generando un consumo excesivo de combustible. Muchos gobiernos han intentado lidiar con este problema agregando más infraestructura, logrando con esto un aumento del tráfico (Tang, Kanamori, y Yamamoto, 2019). Resolver este problema resulta clave, ya que el transporte es vital para el desarrollo urbano; este facilita el acceso a empleos, educación, servicios, y contribuye significativamente al crecimiento económico (Ou, 2022).

Los Sistemas de Transporte Inteligente (ITS, por su sigla en inglés), sistema integrado de sensores de datos IoT (internet de las cosas), cámaras y computadoras proveen una solución al problema del tráfico. Y dentro de los ITS, uno de los problemas más desafiantes es la predicción de tiempo de viaje (TTP, por su sigla en inglés) (Islek y Oguducu, 2019). El TTP refiere a predecir el tiempo de viaje futuro en base a datos históricos y en tiempo real (Elmi y Tan, 2020). Es esencial en los Sistemas Avanzados de Información para Viajeros (ATIS, por su sigla en inglés) y en aplicaciones de navegación. Ayuda en la estimación de hora de llegada, planificación y optimización de rutas, gestión de tráfico y congestión, entre otros (Wang y cols., 2023; Chughtai, ul Haq, ul Islam, y Gani, 2022; Chughtai, Haq, y Muneeb, 2022). Para el caso particular de los ómnibus, un

TTP preciso es un indicador importante para proporcionar un servicio confiable y atractivo para los pasajeros (Moosavi, Aghaabbasi, Yuen, y Armaghani, 2023).

El objetivo principal de este estudio es llevar a cabo una Revisión Sistemática (RS) de la literatura para abordar el estado del arte sobre el tema Predicción de Tiempos de Viaje. Relevar y entender qué se ha investigado hasta ahora, cuáles son las características del problema, los aspectos a tener en cuenta al momento de la predicción y cuáles son los métodos que se utilizan o han sido utilizados. Una RS es un método que permite evaluar la información disponible sobre una pregunta de investigación en particular y tiene como objetivo presentar una evaluación del tema de una manera confiable y rigurosa (Kitchenham, 2004).

Cabe aclarar que el problema del TTP es muy amplio y puede aplicarse a diversos contextos. El enfoque de esta revisión es el ámbito vial, es decir, predecir el tiempo de viaje en las vías de circulación, incluyendo carreteras, calles y autopistas, tanto para el transporte público como privado.

Para que el TTP sea más preciso se debe tener en cuenta una variedad de factores por los que puede verse afectado. Según los autores Fan, Li, Lv, y Zhao (2021), Deb, Khan, Tanvir Hasan, Khan, y Alam (2019) y Bharathi, Sopeña, Clarke, y Ghosh (2023) entre los factores que afectan la predicción se encuentran las condiciones climáticas, la hora de partida, el largo del viaje, las condiciones de la carretera, la fecha y hora del día, ya que no es lo mismo el tránsito en hora pico de día laboral que por ejemplo un fin de semana. También se debe considerar factores externos como eventos o accidentes de tránsito. A su vez, para el caso particular de los autobuses, medio de transporte reconocido por ser la solución más eficiente y de menor costo al momento de mitigar la congestión y las demandas del tráfico, se debe tener en cuenta la cantidad de paradas, el tiempo en cada una de ellas, y el flujo de pasajeros; estos factores pueden generar arribos tempranos o tardíos, causando la pérdida de confianza de los pasajeros y que prefieran el transporte privado (Alkilane, Alfateh, y Yanming, 2023). La precisión en estas predicciones es fundamental para ofrecer un servicio de transporte público competitivo en áreas urbanas frente a otros modos de transporte (Petersen, Rodrigues, y Pereira, 2019).

Para llevar a cabo la predicción, a lo largo de la literatura se encuentra una gran diversidad de métodos, algunos más simples, otros mucho más complejos. Métodos estadísticos que tienen un bajo costo computacional, pero también una precisión muy baja; métodos de histórico promedio que asumen que el tráfico es constante, pero también tienen una baja habilidad de predicción; métodos orientados a datos que tienen la capacidad de extraer patrones ocultos de los datos de entrada (Sihag, Parida, y Kumar, 2022), entre otros.

Entre los métodos orientados a datos se encuentran los métodos de *Machine Learning* (ML), rama de la Inteligencia Artificial (IA) cuya premisa es que los sistemas aprenden de datos y pueden tomar decisiones a partir de ese aprendizaje; se construyen modelos con datos históricos que se van entrenando y mejorando automáticamente (Ou, 2022).

Dentro del ML, se encuentran los métodos de *Deep Learning* (DL); familia de métodos de ML que trabajan con una gran cantidad de datos en un espacio de muchas dimensiones (Nithishwer, Kumar, y Vanajakshi, 2022). Los enfoques

basados en DL cada vez reciben más atención en los problemas de TTP debido a su capacidad de resolver problemas complejos (Nithishwer y cols., 2022), y de determinar “relaciones no lineales complejas entre variables” (Elmi y Tan, 2020). Tienen la capacidad de descubrir mucha información oculta en los datos y obtener excelentes rendimientos en diferentes tipos de problemas (Y. Huang, Dai, y Tseng, 2022). En el Capítulo 3 se aborda con mayor profundidad los métodos utilizados para el TTP. Se presenta una posible clasificación de los métodos, con sus características, ventajas y desventajas.

El resto del documento está organizado como sigue. En el Capítulo 2 se examinan tres elementos importantes en el problema de TTP que se describen a continuación. En la Sección 2.1 se presenta los diferentes factores que pueden influir en la predicción. Debido a que los datos representan un papel importante en el TTP, se destina una Sección 2.2 para abordar en detalle cómo se obtienen y se procesan los mismos, desde la eliminación de datos atípicos, hasta completar datos faltantes, identificar patrones, etc. Por último, se presenta la Sección 2.3, que presenta la diferencia de predecir en el corto plazo y en el largo plazo.

En el Capítulo 3 se presenta una posible clasificación de los métodos con algunos ejemplos. Por último, se abordan los Capítulos 4 y 5, los cuales tienen un enfoque transversal al proceso de predicción. Dado que la predicción puede variar significativamente según el contexto y el tipo de vehículo, el Capítulo 4 está dedicado a este propósito. En el Capítulo 5, se presentan los enfoques para resolver la predicción, destacando entre los más utilizados el enfoque basado en segmento (cuando se conoce la ruta) y el enfoque basado en Origen-Destino (OD), que se utiliza cuando solo se conocen esos dos puntos y no la ruta completa. Por último, se presentan las conclusiones y los anexos que complementan este estudio.

1.2. Revisión Sistemática

En esta Sección se presenta los pasos llevados a cabo para recuperar y seleccionar los artículos que van a formar parte de la revisión sistemática del Estado del Arte.

1.2.1. Formulación del string de búsqueda

En primer lugar, se realizaron búsquedas en las colecciones: Springer Link, Scopus, IEEE Xplore y ScienceDirect. Esta decisión fue tomada en base a una recomendación de los tutores. Las búsquedas fueron realizadas al 17 de setiembre de 2023.

Se partió del *string* “*travel time prediction*”, que se procuró buscar de forma genérica en todo el texto. Se decidió no incluir específicamente el *string* “*travel time estimation*”, ya que tras una búsqueda específica se constató que son términos con definición diferente (Mori, Mendiburu, Álvarez, y Lozano, 2015).

Esta búsqueda inicial dio un total de 6544 resultados. Al ser este un número demasiado alto, se decide buscar dicho *string* únicamente en la Sección *title*.

Esta segunda búsqueda redujo los resultados a 707.

$$s1 = TITLE("travel\ time\ prediction")$$

A partir de este resultado, se procede a depurar la búsqueda identificando términos relevantes para nuestro problema. Los términos identificados fueron los siguientes: “internet of vehicle” (IoV), “arrival time prediction” (ATP), “intelligent transportation system” (ITS), “deep learning” (DL), “machine learning” (ML) y “artificial intelligence” (AI). En Anexo A se presenta en detalle el peso que estos términos aportan a la búsqueda.

Una vez identificado los términos relevantes, se procede a concatenarlos al *string* inicial. Debido a la importancia de estos términos, se procede a buscarlos en el *abstract*. El *string* reformulado es el siguiente:

$$s2 = ABS ("internet\ of\ vehicle" OR "arrival\ time\ prediction" OR "intelligent\ transportation\ system" OR "deep\ learning" OR "machine\ learning" OR "artificial\ intelligence") AND s1$$

Cabe aclarar que los buscadores Springer Link y ScienceDirect no tienen un campo de búsqueda *abstract*, por lo que hubo que realizar pequeñas modificaciones. En Anexo A se presenta en detalle los pasos seguidos.

Tras haber fijado este *string* de búsqueda se obtuvo un total de 215 resultados, los cuales se exportaron a formato .csv para poder pasar a la siguiente etapa de exclusión por criterios.

1.2.2. Criterios de exclusión

El primer criterio que se consideró fue el de eliminar los duplicados. Luego de eliminar duplicados, la cifra se redujo a 161.

Posteriormente, se realizó una exclusión por idioma. Se observó que los artículos recuperados hasta el momento estaban en inglés y cuatro en chino, por lo que se procedió a eliminar estos últimos. Todos ellos eran de la colección Scopus. Los resultados se redujeron a 157.

El siguiente criterio de exclusión utilizado fue descartar aquellos trabajos que tuvieran en el título las palabras *train* y *vessel*, haciendo referencia a trenes y barcos. Este criterio fue tomado dado el contexto del proyecto, que se centra en la predicción del tiempo de viaje para vías terrestres, como por ejemplo vehículos particulares, ambulancias, ómnibus o taxis. Hubo 3 resultados descartados, uno de Scopus, uno de IEEE y otro de ScienceDirect. Dejando un total de 154 artículos. La Tabla 1.1 presenta un resumen del proceso de formulación y exclusión, categorizados por colecciones y etapas del proceso.

Debido a que la cantidad de artículos aún era muy grande para comenzar el análisis, y los criterios de exclusión no estaban sirviendo para realizar una reducción más significativa, se procede a ordenar los artículos por año y a seleccionar los de los últimos 4 años, 2019 a 2023.

Colección	s1	s2	Sin duplicados	Criterios exclusión
Springer Link	44	41	41	41
Scopus	487	128	74	69
IEEE Xplore	120	30	30	29
Science Direct	56	16	16	15
Total	707	215	161	154

Tabla 1.1: Resumen de cantidad de resultados.

Colección	2019	2020	2021	2022	2023	Total
Springer Link	1	4	1	3	4	13
Scopus	5	1	5	12	3	26
IEEE Xplore X	3	1	3	3	-	10
Science Direct	2	1	1	2	1	7
Total	11	7	10	20	8	56

Tabla 1.2: Desglose de los artículos recuperados para analizar.

Esto arrojó un resultado de 76 artículos. De estos 76, 20 no se pudieron recuperar por cuestiones de acceso. Esto dejó un total de 56 artículos a analizar. La Tabla 1.2 y la Gráfica 1.1 detallan la cantidad de artículos recuperados por año y colección.

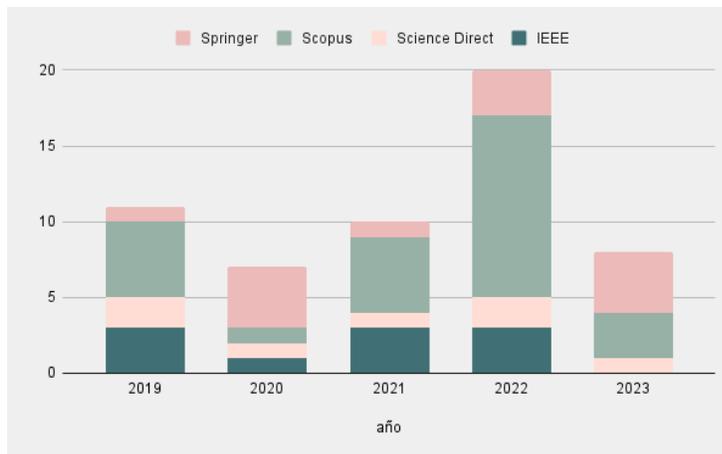


Figura 1.1: Artículos recuperados por año y colección. 2019 al 17/09/2023.

De estos 56 artículos, luego de leer el *abstract* se determinó que tres de ellos no guardan relación con nuestro problema y uno de ellos solo es una corrección a otro de los artículos donde indica que el mismo pasa a ser *open access*. Esto reduce a **52** la lista de artículos finales.

Como último paso, se selecciona un enfoque para analizar estos artículos. Dado que el problema de la predicción del tiempo de viaje es complejo y abarca múltiples aspectos, no fue posible identificar categorías disjuntas. Por lo tanto, se opta por dos criterios de análisis. En primer lugar, se examinarán los diferentes elementos que participan en el proceso de predicción. Segundo, se analizarán aquellos aspectos transversales al proceso de predicción como lo son el contexto, el tipo de vehículo y el enfoque a abordar para resolver el problema de TTP. En la siguiente Sección 1.2.3, se profundiza en estos dos criterios.

1.2.3. Categorización de artículos

El primer criterio que se considera para analizar los artículos es considerar los diferentes elementos a tener en cuenta en el **proceso** de predicción:

1. El primer elemento a analizar que afecta a la predicción son los **factores**, que pueden ser muy variados, como las condiciones climáticas, congestión, semáforos y eventos externos. La Sección 2.1 profundiza en este tema.
2. El siguiente elemento a considerar son los **datos**, una pieza fundamental en este problema. Se analizan aspectos como la fuente de origen, depuración, calidad, cantidad y tipo de datos. La Sección 2.2 aborda este tema en detalle.
3. Luego, debe contemplarse el **horizonte de predicción**, es decir, si se desea una predicción a corto o largo plazo. La Sección 2.3 profundiza sobre este tema.
4. El último elemento a tener en cuenta en este proceso es la elección del **método** de predicción, el cual depende de los 3 puntos mencionados anteriormente. El Capítulo 3 presenta los métodos relevados a través de una clasificación.

La Tabla 1.3, muestra los artículos considerados para el desarrollo del Capítulo 2 “Factores, Datos y Horizontes”, y para el Capítulo 3 “Modelos de predicción de tiempos de viaje”:

1. La columna factores, muestra los artículos utilizados en la Sección 2.1 “Factores que afectan el tiempo de viaje”.
2. La columna Datos, muestra los artículos utilizados en la Sección datos 2.2 “Recopilación y Procesamiento de Datos”.
3. La columna Horizonte, muestra los artículos utilizados en la Sección 2.3 “Horizontes de Predicción”.

4. La columna Método, muestra los artículos utilizados en el Capítulo 3 “Modelos de predicción de tiempos de viaje”.

Tabla 1.3: Artículos utilizados en el análisis del proceso de predicción.

Año	Autor	Factores	Datos	Horizonte	Método
2019	Chang, Li, Fu, Liu, y Yang	-	✓	-	-
2019	Deb y cols.	-	✓	-	✓
2019	He, Jiang, Lam, y Tang	-	-	-	✓
2019	Islek y Oguducu	✓	-	✓	-
2019	Kumar, Jairam, Arkatkar, y Vanajakshi	-	✓	-	-
2019	Ran, Shan, Fang, y Lin	-	-	-	✓
2019	Tang y cols.	-	-	✓	-
2019	Ghosal	-	✓	-	-
2020	Abdollahi, Khaleghi, y Yang	-	-	-	✓
2020	C. Chen, Wang, Yuan, Jia, y Yao	-	-	-	✓
2020	Elmi y Tan	✓	✓	-	-
2020	H. Huang, Pouls, Meyer, y Pauly	-	-	✓	✓
2020	Jakteerangkool y Muangsin	-	✓	-	✓
2020	Mendes-Moreira y Baratchi	-	-	✓	-
2020	K. Zhang, Lai, Jiang, y Yang	✓	✓	-	✓
2021	Fan y cols.	-	✓	-	✓
2021	Fiosina	-	✓	-	-
2021	X. Li, Wang, Sun, y Zu	-	-	-	✓
2021	Qiu y Fan	-	✓	✓	✓
2021	Schwinger, Frohnhofen, Wernz, Braun, y Jarke	-	-	-	✓
2021	Thakkar, Sharma, Advani, Arkatkar, y Bhaskar	-	✓	-	✓
2021	Xu y Liu	-	-	-	✓
2021	L. Zhang y cols.	-	-	-	✓
2021	Kumar, Mothukuri, y Vanajakshi	-	✓	-	-
2022	Ahmed y cols.	-	-	-	✓
2022	Ashwini, Sumathi, y Sudhira	-	-	-	✓
2022	M. Y. Chen, Chiang, y Yang	-	✓	-	✓
2022	Chughtai, Haq, Shafiq, y Muneeb	✓	-	-	✓
2022	Chughtai, ul Haq, y cols.	-	-	✓	-
2022	Chughtai, Haq, y Muneeb	-	✓	-	✓
2022	Fang y cols.	-	-	-	✓
2022	Y. Huang y cols.	-	-	✓	-
2022	Katayama, Yasuda, y Fuse	-	-	-	✓
2022	Khaled, Elsir, y Shen	-	-	-	✓
2022	Lee y cols.	✓	-	-	-

Tabla 1.3 – Continuación.

Año	Autor	Factores	Datos	Horizonte	Método
2022	Nithishwer y cols.	-	✓	-	✓
2022	Ou	-	-	-	✓
2022	Shen, Jin, Hua, y Huang	✓	-	-	✓
2022	Sihag y cols.	-	✓	✓	-
2022	Y. Li, Zhang, Ding, Zhou, y Xu	-	✓	-	-
2023	Alkilane y cols.	-	-	-	✓
2023	Bharathi y cols.	-	✓	-	✓
2023	C. Y. Chen, Sun, Chang, y Lin	-	-	-	✓
2023	N. Li y cols.	-	-	-	✓
2023	Moosavi y cols.	✓	✓	-	✓
2023	Pérez-González, Mora-Vargas, Piña-Barcenás, y Cedillo-Campos	-	✓	-	-
2023	Putatunda y Laha	-	-	-	✓
2023	Wang y cols.	✓	✓	-	✓

El segundo criterio que se considera para llevar a cabo la Revisión Sistemática, es contemplar todos aquellos factores transversales al proceso de predicción. Estos son el **tipo de vehículo**, el **entorno** del problema y el **enfoque**. Los Capítulos 4 y 5 abordan el problema de predicción desde esta perspectiva. Resulta de interés analizar estos aspectos, ya que las características del problema pueden variar significativamente:

1. El **tipo de vehículo** es relevante, ya que pueden afectar elementos como la conducta del conductor o si la ruta es fija y conocida o variable. Los tipos de vehículos que se analizaron son vehículo particular, taxi y autobús. La Sección 4.1 profundiza sobre este tema.
2. El **entorno** es importante, ya que la fluidez del tránsito es bien diferente si nos encontramos en un entorno urbano o autopista. La Sección 4.2 profundiza sobre este tema.
3. Por último, el **enfoque**, aborda el problema de predicción desde la perspectiva de si se conoce el camino o solo los puntos de origen y destino. El Capítulo 5 profundiza en este tema.

La Tabla 1.4, muestra los artículos considerados para el desarrollo del Capítulo 4 “Clasificación de predicción de tiempos de viaje”, y para el Capítulo 5 “Enfoques para resolver la Predicción del tiempo de Viaje”:

1. La columna Vehículo, muestra los artículos utilizados en la Sección 4.1 “Clasificación según el tipo de vehículo”.
2. La columna Entorno, muestra los artículos utilizados en la Sección 4.2 “Clasificación según el entorno”.

Tabla 1.4: Artículos considerados en el análisis del tipo de vehículo, Entorno y Enfoque.

Año	Autor	Vehículo	Entorno	Enfoque
2019	Deb y cols.	✓	-	-
2019	Tang y cols.	-	✓	-
2020	C. Chen y cols.	✓	-	-
2020	Elmi y Tan	✓	-	-
2020	H. Huang y cols.	✓	-	-
2020	Mendes-Moreira y Baratchi	✓	-	-
2020	K. Zhang y cols.	✓	-	✓
2021	Fan y cols.	-	✓	-
2021	Fiosina	✓	-	-
2021	Qiu y Fan	-	✓	-
2021	Schwinger y cols.	✓	-	-
2021	Thakkar y cols.	-	✓	-
2021	Xu y Liu	-	✓	-
2021	L. Zhang y cols.	-	✓	-
2022	Ashwini y cols.	✓	✓	-
2022	M. Y. Chen y cols.	-	✓	-
2022	Chughtai, Haq, Shafiq, y Muneeb	✓	-	✓
2022	Chughtai, Haq, y Muneeb	-	-	✓
2022	Chughtai, Haq, Shafiq, y Muneeb	✓	-	-
2022	Katayama y cols.	✓	-	-
2022	Khaled y cols.	-	-	✓
2022	Elsir, Khaled, Wang, y Shen	-	-	✓
2022	Nithishwer y cols.	✓	-	-
2023	Bharathi y cols.	-	✓	-
2023	C. Y. Chen y cols.	-	✓	-
2023	Moosavi y cols.	✓	-	-
2023	Putatunda y Laha	✓	-	-
2023	Wang y cols.	✓	-	-

3. La columna Enfoque, muestra los artículos utilizados en el Capítulo 5 “Enfoques para resolver la Predicción del tiempo de Viaje”.

A partir de este punto, los Capítulos siguientes abordan la Revisión Sistemática en base a los dos criterios previamente mencionados.

Capítulo 2

Factores, Datos y Horizontes de Predicción

Antes de iniciar el proceso de entrenar un modelo de predicción se necesita evaluar diferentes aspectos. Es necesario seleccionar los factores a tener en cuenta para la predicción, desde factores elementales como marca de tiempo y ubicación hasta factores externos como eventos sociales. La Sección 2.1 profundiza en el abanico de factores a tener en cuenta.

Además, es necesario obtener y preparar los datos que el modelo va a utilizar. Por esta razón, la Sección 2.2 releva todo el proceso por el que pasan los datos antes de ser utilizados por modelo de predicción; desde relevar y eliminar valores atípicos, hasta identificar patrones y elegir la representación de los mismos.

Por último, se debe evaluar si se va a efectuar una predicción a corto o largo plazo. En la Sección 2.3 se profundiza en estos conceptos a modo de entender qué los diferencia.

2.1. Factores que afectan el tiempo de viaje

Los factores que afectan a la predicción del tiempo de viaje pueden ser muy diversos y variados. Entre ellos tenemos la congestión, las condiciones climáticas, factores externos, como por ejemplo eventos especiales o manifestaciones que generan un flujo atípico de personas y pueden afectar la fluidez del tránsito (Elmi y Tan, 2020).

Los autores Wang y cols. (2023) clasifican estos factores en:

1. Dependencia Temporal: refiere a factores relacionados con la dimensión tiempo, como momento del día, hora o día de la semana. El tráfico varía significativamente entre días de semana y fin de semana, así como en horarios pico.

2. Dependencia Espacial: refiere a las características espaciales de la carretera como límites de velocidad, flujo de tráfico y reglas de tránsito. La predicción del tiempo de viaje para un segmento no solo está afectado por su propio estado, sino por los segmentos que conectan a él.
3. Dependencia Exógenas: refiere a factores externos, como el clima, conducta del conductor, accidentes de tráfico. Factores que son externos al sistema de transporte pero que tienen influencia directa en las condiciones de tráfico y el tiempo de viaje.

Esta clasificación proporciona una estructura clara para entender los distintos factores que pueden influir en la predicción del tiempo de viaje. A continuación, se profundiza en algunos de estos factores, con el objetivo de comprender un poco más cómo cada tipo de dependencia afecta en la predicción.

Las condiciones climáticas, que pueden variar desde la precipitación, como la lluvia o la nieve, hasta fenómenos como el viento fuerte o la presencia de niebla, pueden reducir la visibilidad y la tracción en la carretera, afectando así la velocidad de desplazamiento de los vehículos y aumentando el riesgo de accidentes. Asimismo, las heladas, especialmente en regiones con temperaturas bajo cero, pueden generar hielo en la calzada, tornándola peligrosa para la conducción. Los autores [Chughtai, Haq, Shafiq, y Muneeb \(2022\)](#) realizaron un amplio estudio donde consideraron un gran número de características espacio-temporales y climáticas. En particular, consideraron 18 condiciones meteorológicas en su conjunto final de características, desde un día completamente despejado hasta condiciones de lluvia torrencial, y realizaron un experimento específico para evaluar el impacto de las condiciones climáticas en el TTP. El experimento les permitió concluir que, en general, las características climáticas tienen un efecto considerable.

Las características de la infraestructura vial también desempeñan un papel crucial en el TTP. Según [Shen y cols. \(2022\)](#), la estructura de la red vial, incluyendo la conectividad de las carreteras y la presencia de intersecciones, influye significativamente en los tiempos de viaje.

Finalmente, factores externos como eventos imprevistos, congestión urbana debido a semáforos y densidad de tráfico en áreas urbanas también pueden agregar complejidad al TTP. Por ejemplo, [K. Zhang y cols. \(2020\)](#) mencionan factores relacionados con las condiciones del vehículo y hábitos del conductor. [Moosavi y cols. \(2023\)](#) mencionan que para el caso particular de la predicción para autobuses, un factor destacado que afecta de manera significativa es el retraso desde el tiempo de salida programado hasta el momento en que el autobús sale efectivamente de la terminal ([Moosavi y cols., 2023](#)).

Así como algunos autores se centran en un grupo específico de características, otros han llevado a cabo estudios más complejos donde consideran una amplia variedad de características en sus experimentos. Uno de los ejemplos destacados en el caso particular del TTP para autobuses es el estudio realizado por [K. Zhang y cols. \(2020\)](#). Entre los factores que incluyen se encuentran la condición climática, la identificación del conductor y del vehículo, la identificación del intervalo de

tiempo, el día de la semana, la temperatura y la descripción del clima, así como también la información del conductor asignado a la trayectoria según los datos del horario.

Por otro lado, [Lee y cols. \(2022\)](#) en su estudio también para ómnibus, consideran una gran variedad de características espaciales-temporales y su impacto en la predicción. En su investigación, dividen el TTP para los ómnibus en dos partes: predecir el tiempo de viaje en movimiento y el tiempo de espera. Por lo tanto, contemplan otros factores como la cantidad de personas que suben y/o bajan en cada parada. En su investigación, llevaron a cabo diversos experimentos en los que eliminaron variables específicas para evaluar su impacto en la predicción. En cada uno de estos experimentos, se eliminó un factor diferente: en uno se eliminaron las variables relacionadas con los pasajeros, en otro se excluyeron las variables asociadas a los enlaces (velocidad del enlace, número de carriles), y en otro se descartaron las variables climáticas. En todos los casos, se observó que al eliminar alguno de estos grupos variables, la tasa de error aumentaba, ya sea de forma marginal o significativa. Esto condujo a la conclusión de que todos los factores mencionados anteriormente son relevantes, destacando especialmente aquellos relacionados con las características de los enlaces.

Además de los factores mencionados anteriormente, es importante destacar que, si bien hay estudios que consideran diferentes factores externos en la predicción, existen otros que realizan un estudio más simplificado donde utilizan la mínima cantidad de información posible. Algunos trabajos de investigación se centran en la predicción del tiempo de viaje, basándose únicamente en variables como la velocidad promedio histórica en la ruta y la distancia recorrida. Estos enfoques minimalistas buscan simplificar los modelos de predicción y reducir la dependencia de datos complejos o difíciles de obtener, lo que puede ser especialmente útil en situaciones donde la disponibilidad de información detallada es limitada. Aunque estos modelos pueden no capturar todos los matices de las condiciones del tráfico y del entorno, proporcionan una aproximación útil y práctica para la estimación del tiempo de viaje en ciertas circunstancias. Un ejemplo de esto es el estudio realizado por [Islek y Oguducu \(2019\)](#) donde solo consideran velocidad promedio, fecha y hora en que se recibieron los datos del enlace, y datos para identificar el segmento sobre el que se está realizando la predicción como identificador, nombre y municipio.

En conclusión, los factores que afectan y se utilizan en el TTP son numerosos y dependen de diversas variables. Esto incluye el tipo de predicción que se intenta realizar, ya sea para vehículos de transporte público con recorridos y horarios establecidos, como autobuses, o para vehículos de transporte privado, como taxis, así como para otros medios de transporte. Además, estos factores están condicionados por entornos diversos, por ejemplo en entornos urbanos la predicción puede verse afectada por elementos como semáforos, eventos y otros. Además, influyen las condiciones climáticas y el estado de las vías. Por último, es importante considerar el costo computacional asociado; si bien una mayor cantidad de factores puede mejorar la precisión, también puede complejizar el modelo y ralentizar la predicción. Ahondaremos en este aspecto en el Capítulo 4.

En resumen, es crucial encontrar un equilibrio entre la precisión de la predicción y la eficiencia del método utilizado.

2.2. Recopilación y procesamiento de datos

Una pieza clave en la predicción del tiempo de viaje son los datos a utilizar. Por ese motivo, en esta Sección se presenta todo el proceso por el que pasan los datos antes de estar listos para ser utilizados en el modelo de predicción.

Como se presentó en la Sección 2.1, la predicción del tiempo de viaje puede verse afectada por múltiples factores, como el día de la semana, la hora del día, la duración del viaje, la ubicación geográfica, eventos locales, las condiciones climáticas y de la carretera, etc. Dependiendo de la complejidad del método de predicción y el tipo de vehículo para el que se realice, es el tipo y cantidad de datos a utilizar. Por ejemplo, para el caso de la predicción para ómnibus, un factor clave es el tiempo que el ómnibus permanece en una parada subiendo o descargando pasajeros (K. Zhang y cols., 2020).

Para obtener los datos es necesario utilizar diferentes dispositivos de recolección. Uno de los dispositivos que se menciona con mayor frecuencia en esta revisión sistemática es el Sistema de Posicionamiento Global (GPS, por su sigla en inglés). Los datos que este dispositivo aporta son: un ID para poder identificar la unidad, latitud y longitud de la ubicación por la que pasa el vehículo y la marca de tiempo de cuando se obtiene el registro (Kumar y cols., 2019, 2021; Pérez-González y cols., 2023; Fan y cols., 2021; Sihag y cols., 2022; Jakteerangkool y Muangsin, 2020; Ghosal, 2019). Luego estos datos se procesan y se utilizan para obtener información clave, como por ejemplo la duración del viaje, tomando la marca de tiempo del primer y último registro, o el sentido del viaje, es decir, desde donde sale el vehículo y hacia donde va (Sihag y cols., 2022). También se puede relevar el tiempo de salida, que es la marca de tiempo del primer registro, o la distancia del viaje utilizando las coordenadas de latitud y longitud de los registros extremos, o el día de la semana a partir de la marca de tiempo (Fan y cols., 2021). En Kumar y cols. (2019), Kumar y cols. (2021) y Nithishwer y cols. (2022) utilizan la fórmula de Haversine como herramienta para el cálculo de la distancia entre dos ubicaciones GPS.

Otro dispositivo que se puede utilizar para relevar datos es el detector de bucle, dispositivo instalado bajo la superficie de la carretera, que detecta cuando un vehículo pasa sobre él (Jakteerangkool y Muangsin, 2020; Thakkar y cols., 2021). Los autores Bharathi y cols. (2023) en su estudio, utilizan 6 detectores de vehículos consecutivos ubicados en la M50, una de las autopistas más concurridas de la ciudad de Dublín. Los datos crudos relevados de estos detectores fueron marca de tiempo de cuando se detecta el vehículo, la velocidad, el tipo de vehículo y un identificador de carril.

Y. Li y cols. (2022) destaca que si bien los datos de vehículos de sonda¹ (PVD, por sus siglas en inglés) se han vuelto populares, como por ejemplo INRIX, DiDi,

¹Datos de Vehículos de Sonda(PVD) también conocidos como FCD.

datos GPS de taxis, no se puede ignorar que hay áreas a las que no se puede acceder a esos datos por cuestiones de políticas y penetración de mercado, motivo por el que consideran que los detectores no serán completamente reemplazados por este otro tipo de dispositivo en un futuro cercano.

Algunos autores no hacen mención específica al dispositivo hardware utilizado en el relevamiento de los datos, sino que directamente mencionan los sistemas de recolección. Tal es el caso del estudio de [Moosavi y cols. \(2023\)](#), estudio bastante complejo sobre la predicción del tiempo de viaje en autobús. Ellos utilizan tres fuentes de información diferentes. Por un lado, utilizan el sistema de Localización Automática de Vehículos (AVL, por su sigla en inglés), que luego de convertir los datos permite obtener hora de salida y llegada, tiempo de recorrido de un segmento, y duración del viaje completo, utilizando técnicas de *geofencing*². Otro de los sistemas que utilizan es el AFC³, el cual proporciona datos sobre cada transacción que la persona realiza al subir al ómnibus. Entre los datos que este sistema proporciona se incluye hora, fecha, ubicación (parada de autobús), así como datos personales de los pasajeros como género, edad e incluso ocupación. Por último, para obtener la información sobre la hora de apertura/cierre de las puertas del autobús y el número de pasajeros que suben y bajan, utilizan el sistema APC⁴.

Otro factor que aparece mucho es el clima. Para obtener estos datos es necesario acceder a reportes climáticos. Por ejemplo, en el caso de [Deb y cols. \(2019\)](#) los datos son obtenidos de *Wunderground*⁵, servicio que proporciona información meteorológica actual e histórica.

En la literatura se menciona muchos otros dispositivos/tecnologías/sistemas de recolección de datos en los cuales no ahondaremos, pero se mencionan para conocer de su existencia. [Jakteerangkool y Muangsin \(2020\)](#) mencionan técnicas de recopilación de datos que utilizan sensores, por ejemplo cámaras de reconocimiento de matrículas o sensores Bluetooth, instalados en puntos específicos de la carretera. [Thakkar y cols. \(2021\)](#) mencionan la utilización de sensores Bluetooth/Wi-Fi que rastrean los movimientos del vehículo mediante la identificación de la MAC-id del dispositivo móvil. En [Qiu y Fan \(2021\)](#) mencionan que los datos fueron obtenidos de RITIS, un sistema avanzado de análisis de datos de tráfico. Otra fuente de información que aparece es *Floating Car Data* (FCD), tecnología que permite recopilar información como ubicación, identificador de vehículo, marca de tiempo, etc. ([Fiosina, 2021](#); [Chughtai, Haq, y Muneeb, 2022](#)). También se mencionan Uber Movement ([Deb y cols., 2019](#)) y Google Map API ([M. Y. Chen y cols., 2022](#)).

Luego de relevar los datos es necesario procesarlos. Este procesamiento puede incluir tareas de complementar la base de datos con más información, remover datos atípicos, incorrectos o irrelevantes, completar datos faltantes o llevar a cabo tareas de filtrado para aquellos casos en que la base de datos tenga datos que no son de interés para el estudio. No todos los experimentos llevan a cabo

²Creación de límites virtuales basados en ubicación. [Geofencing](#).

³Sistema Automatizado de Recaudo.

⁴Sistema de conteo automático de pasajeros.

⁵Sitio: [Wunderground](#).

las mismas tareas, esto depende de la calidad y cantidad de datos disponibles, así como el tipo de datos que se maneje.

Como se menciona anteriormente, una de las tareas que puede formar parte del procesamiento de datos es la inferencia de nuevos datos para agregar a la base de datos. Además de los datos crudos que se pueden obtener de los dispositivos, y los datos ya mencionados en párrafos anteriores que se pueden inferir de los originales, también es posible agregar un identificador de trayectoria, para poder identificar todos los registros que se corresponden al mismo trayecto (Sihag y cols., 2022) o un identificador de ruta, del vehículo y de viaje (Kumar y cols., 2019), entre otros.

En la etapa de eliminación de valores atípicos, se eliminan datos poco razonables que no reflejaban las características de los sitios de estudio (Bharathi y cols., 2023), lo cual depende mucho de las características del problema. Por ejemplo, para el caso de Sihag y cols. (2022) consideran tres criterios. Primero eliminan los datos que están a una distancia mayor a 50 km de los dos extremos del área de estudio. Luego eliminan registros con valores atípicos. Considerando valores atípicos aquellas trayectorias cuyo tiempo de viaje es mayor al tiempo de caminata (5 km/h) o superior al 150 % o inferior al 50 % del tiempo de viaje de los viajes adyacentes. En el caso de Fan y cols. (2021) consideran valores atípicos aquellas trayectorias que eran muy cortas o muy largas; que después de un análisis concluyen que se debe a muestreos incompletos o a trayectos que exceden el área de estudio y proceden a eliminar. Otro mecanismo que se puede utilizar para eliminar datos atípicos es el criterio de rango intercuartílico⁶ (Pérez-González y cols., 2023).

Luego de eliminar los valores atípicos, se puede analizar el problema de la falta de datos. En el caso de los detectores de tráfico en Chang y cols. (2019) se considera que esta falta puede ser causada por problemas internos o externos de los detectores. Como mecanismo para completar datos faltantes, utilizan la interpolación, proceso de estimar valores faltantes basándose en datos conocidos. Algunos de los métodos de interpolación son el *método del valor más cercano* que consiste en tomar el promedio de varios datos más cercanos, el *método de interpolación lineal* que consiste en obtener un punto de la línea recta formada por dos puntos conocidos a partir de la fórmula

$$y = \frac{y_1 - y_0}{x_1 - x_0}(x - x_0) + y_0$$

y el *método de la curva spline cúbica* que consiste en obtener un nuevo punto utilizando una función sinusoidal. Otra posible causa de la falta de datos puede ser la propia naturaleza del problema. Un ejemplo de esto se encuentra en el estudio de Ghosal (2019), donde se intenta predecir el tiempo de viaje utilizando un conjunto de datos pequeño, compuesto por 14,500 viajes de taxis de Uber.

⁶El rango intercuartílico es una técnica estadística utilizada para identificar valores atípicos en un conjunto de datos. Los valores que están por encima del límite superior o por debajo del límite inferior se consideran atípicos y pueden ser eliminados o tratados de manera especial en el análisis de datos.

En este estudio, se menciona que solo el 3% de los enlaces viales son recorridos por un taxi, lo que dificulta la predicción del tiempo de viaje.

Luego de tener los datos listos, se procede a analizarlos más a fondo en busca de patrones. Los patrones desempeñan un papel significativo en el rendimiento de los métodos de predicción. Se espera que el tráfico de una determinada carretera siga ciertos patrones horarios, diarios o semanales. Entre los patrones horarios se pueden identificar horarios pico y horarios valle. Entre los patrones diarios, el principal patrón está en identificar si es un día semanal o fin de semana, y luego los patrones semanales que refieren a qué mismos días de la semana suelen tener comportamientos de tránsito similares. Poder identificar estos patrones permite identificar cuáles son los datos más significativos y efectivos para mejorar el rendimiento del método de predicción (Kumar y cols., 2019).

Elmi y Tan (2020) clasifica los patrones en tres tipos, espaciales, temporales y de contexto (externos). Los patrones espaciales refieren a que los segmentos de una carretera están fuertemente relacionados, si hay congestión en una carretera en particular se verán afectadas las zonas de alrededor, principalmente las carreteras adyacentes. Los patrones temporales refieren a como se ve afectado el tráfico según la hora del día y el día de la semana. Por último, los patrones de contexto refiere a factores externos como la conducta de los conductores, semáforos, condiciones climáticas o eventos que pueden afectar al tráfico.

Los autores Sihag y cols. (2022) utilizan diferentes técnicas de visualización como *treemaps* y mapas de calor como herramientas para analizar datos e identificar patrones. El *Treemap* es una representación gráfica de rectángulos anidados para representar árboles. Por ejemplo, en el contexto del estudio realizado por los autores previamente mencionados, para identificar patrones semanales, cada recuadro dentro del *treemap* representa un día de la semana y su tamaño y color reflejan la cantidad de tráfico asociada a ese día. El tamaño del recuadro es directamente proporcional a la cantidad del tráfico y el color se asocia en el espectro de rojo a verde, siendo rojo el recuadro que representa el día de la semana con mayor tráfico y verde el menor. Con esta herramienta, un patrón que identificaron es que el tiempo de viaje más largo se da entre semana, mientras que el más corto se da los domingos, quedando el sábado en el medio, lo cual se justifica por el hecho de que es un día laboral pero no para todos los rubros/empresas. A su vez, se identifican los horarios pico de 9 a 11 y de 18 a 20 hs. Si bien el *treemap* es una herramienta muy visual, puede resultar complicado utilizar. El mapa de calor es una herramienta de similares características, ya que muestra los valores mayores en un espectro de colores entre el rojo y el verde, siendo rojo para el valor más alto y verde para el más bajo, pero ahora los datos se muestran ordenados en formato planilla. Por ejemplo, para el mapa de calor para identificar patrones horarios, cada fila del mapa de calor es una hora, ordenadas de 0 a 23 y cada una de las columnas es un día de la semana, ordenados de lunes a domingo.

Por último, se debe decidir cómo representar los datos que se van a utilizar en el modelo. Los autores Wang y cols. (2023) señalan que los datos pueden ser

categoricos⁷ o discretos⁸. Además, mencionan que en los modelos de DL se utiliza ampliamente el método *One-Hot Encoding* para manejar variables categóricas, convirtiendo las características discretas en vectores binarios. Sin embargo, este método no contempla los valores de las características, lo que limita su capacidad de capturar la similitud entre ellas. Asimismo, la codificación *One-Hot* puede llegar a ser demasiado dispersa (con la mayoría de valores en cero) para que los modelos de DL puedan manejarla. Para superar esto, se propone usar el *embedding* de entidad, método que convierte las variables categóricas en vectores numéricos para que los modelos de aprendizaje automático puedan entender y procesar de manera más efectiva la información.

El último tema a considerar sobre los datos es el volumen. Para lograr modelos precisos, la calidad de los datos es fundamental, pero también lo es la cantidad, que varía según el tipo de modelo. Por ejemplo, los modelos orientados a datos necesitan un gran volumen de información (Kumar y cols., 2019). Por lo tanto, es importante contar con suficientes datos para entrenar el modelo y otro conjunto de datos para probarlo. Cuanta más información se tenga disponible, mayor será el rendimiento del modelo.

En conclusión, los datos a utilizar pueden ser muy diversos y obtenerse de muchas fuentes diferentes. Por ejemplo, los datos de tráfico se obtienen principalmente de dispositivos GPS. También se pueden obtener de sistemas más complejos que proveen mayor cantidad de información como por ejemplo los sistemas AVL, o sistemas de información complementaria para obtener datos del clima, o información sobre las paradas de ómnibus o afluencia de pasajeros para el caso del transporte público. Luego de obtener los datos es necesario someterlos a un riguroso procedimiento, donde primero se analizan y se eliminan datos atípicos, incorrectos o relevantes, y se completan datos faltantes. Por último, se buscan patrones, los cuales juegan un papel significativo en el rendimiento de la predicción. Identificar patrones permite encontrar cuáles son los datos más importantes a utilizar para alimentar el método de predicción y de esa forma mejorar su rendimiento. Cuando los datos ya están listos, debe elegirse una forma de representación, para luego poder pasárselos al modelo.

2.3. Horizontes de predicción

El horizonte de predicción refiere al periodo de tiempo en el que se llevará a cabo la predicción y se divide principalmente en corto y largo plazo. No existe un consenso en la literatura sobre la duración exacta de estos conceptos.

El corto plazo se define como la predicción para dentro de unos pocos segundos/minutos, hasta 30 minutos o una hora (Chughtai, ul Haq, y cols., 2022;

⁷Categorico refiere a que se puede clasificar en categorías definidas, como el día de la semana o el tipo de vehículo (auto, moto, camión).

⁸Los datos discretos pueden asumir cualquier valor sin seguir un orden específico y no están limitados a una lista finita o categoría, como el número de pasajeros o el identificador del conductor.

Qiu y Fan, 2021; Y. Huang y cols., 2022; H. Huang y cols., 2020) o incluso unas pocas horas en el futuro (Tang y cols., 2019). Algunos autores son menos precisos, ya que no indican un periodo de tiempo, pero en sus experimentos de corto plazo incluyen intervalos de 5 a 15 minutos (Islek y Oguducu, 2019). Estas predicciones son importantes para las empresas de logística y transporte, porque les permiten gestionar de manera más eficiente las operaciones diarias, así como planificar y asignar recursos de forma inmediata (Qiu y Fan, 2021). También se utiliza mucho en entornos urbanos, donde las condiciones del tráfico son muy cambiantes y se requiere una actualización constante de la información (Tang y cols., 2019), y para la toma de decisiones rápida y en tiempo real para asignar recursos, como taxis, a clientes que solicitan un servicio de manera inmediata (H. Huang y cols., 2020).

Por otro lado, el largo plazo implica un horizonte de predicción mayor que va desde más de una hora (Y. Huang y cols., 2022), un día (Qiu y Fan, 2021; Chughtai, ul Haq, y cols., 2022), hasta varios días (H. Huang y cols., 2020), o al menos una semana (Islek y Oguducu, 2019). Estas predicciones se ven más afectadas por condiciones climáticas o de congestión (Qiu y Fan, 2021). Es utilizada en la planificación anticipada, por ejemplo, cuando los clientes reservan un viaje con varios días de anticipación (H. Huang y cols., 2020). Desempeñan un papel crítico en la planificación del transporte y pueden mejorar las decisiones (Sihag y cols., 2022). Existe un interés creciente en el largo plazo, ya que es una herramienta útil para los usuarios en la gestión del tráfico y la planificación de viajes (Y. Huang y cols., 2022). Sin embargo, la predicción a largo plazo resulta más desafiante y complicada, ya que implica predecir valores de tiempo de viaje para fechas específicas en el futuro, lo que requiere una consideración más amplia de diversos factores y depende de no solo la situación del tráfico reciente, sino de patrones de tráfico históricos (Y. Huang y cols., 2022).

Concluyendo, ambos horizontes se utilizan para la planificación de viajes y gestión del tráfico, y ambos pueden verse afectados por las condiciones del tráfico y factores diversos. La diferencia principal radica en el horizonte de tiempo y en la complejidad. Respecto al horizonte, el significado de corto plazo es más o menos similar para todos los autores, pero para el largo plazo la diferencia es mucho mayor, ya que mientras para unos implica un horizonte de predicción de más de una hora, para otros implica un horizonte mayor a una semana. Respecto a la complejidad, por ejemplo, cuando se implementa predicción a largo plazo, es necesario que los modelos cuenten con componentes que se encarguen de la extracción de patrones históricos periódicos (Y. Huang y cols., 2022).

Los autores Y. Huang y cols. (2022) mencionan que los modelos utilizados para la predicción en el corto plazo logran tener una performance ineficiente cuando enfrentan problemas de largo plazo. En contraposición a esto, Islek y Oguducu (2019) llevan a cabo un experimento donde utilizan el mismo método, LSTM, para ambos horizontes, obteniendo resultados razonables.

Es importante destacar que el tema horizonte de predicción no es abordado (al menos no de manera explícita) en todos los artículos analizados. Sin embargo, Y. Huang y cols. (2022) y Mendes-Moreira y Baratchi (2020) aseguran que la

mayoría de los estudios de TTP se centran en la predicción a corto plazo, y [Sihag y cols. \(2022\)](#) añaden que la predicción a largo plazo es crucial para la planificación del transporte, la reducción de costos, entre otros.

Capítulo 3

Modelos de Predicción de Tiempos de Viaje

Existen decenas de modelos de predicción de tiempos de viaje, y no hay entre los investigadores un criterio unificado de clasificación. Con el fin de brindar una taxonomía que proporcione claridad sobre los modelos, se toma como punto de partida la clasificación de [Mori y cols. \(2015\)](#), por considerar que aporta una visión general del tema. La misma consta de tres grandes clases de modelos: **modelos ingenuos**, **modelos basados en la teoría del tráfico**, y **modelos basados en datos**. Los modelos citados son los que se encuentran con más frecuencia en la literatura. La taxonomía de los modelos de predicción de tiempos de viaje se muestra en la Figura 3.1.

3.1. Modelos ingenuos

Los modelos ingenuos son enfoques simples, fáciles y rápidos para predecir el tiempo de viaje, además de no requerir ningún entrenamiento ni estimación de parámetros. Sin embargo, como explican [Moosavi y cols. \(2023\)](#) si bien estos métodos son simples, tienen suposiciones restrictivas y debilidades que los hacen poco confiables, y por lo tanto no se recomiendan para la predicción del tiempo de viaje. Se utilizan a menudo como línea de base para comparación, ya que cualquier nuevo método de predicción de tiempo de viaje, para ser considerado, debería poder obtener mejores resultados. Los modelos ingenuos además se dividen en predictores instantáneos, predictores históricos y predictores híbridos según las suposiciones que realicen ([Mori y cols., 2015](#)).

3.1.1. Predictores instantáneos

Estos modelos asumen que las condiciones del tráfico permanecerán constantes indefinidamente, algo quizás admisible con un horizonte de tiempo de predicción muy pequeño, pero inadmisibles a medida que el mismo crece. Para

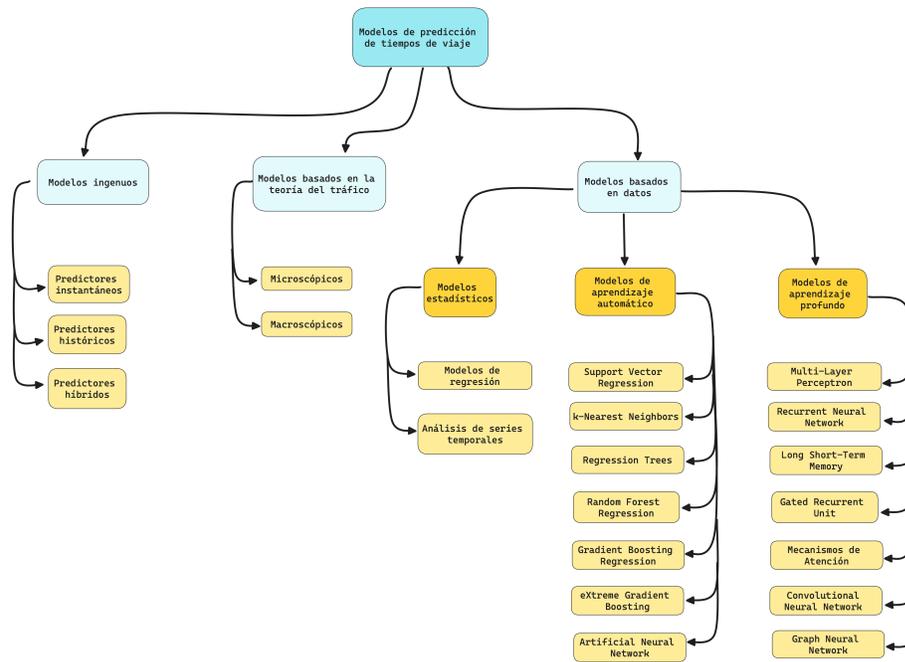


Figura 3.1: Taxonomía de los modelos de TTP. Fuente: elaboración propia.

ser efectivo, este tipo de modelo requiere condiciones de tráfico constantes, y en caso de grandes variaciones en los patrones de tráfico la precisión se verá significativamente afectada (Alkilane y cols., 2023). A partir de esa asunción, el modelo devuelve la predicción más reciente del tiempo de viaje.

3.1.2. Predictores históricos

Estos modelos asumen que el tiempo de viaje en un intervalo de tiempo dado es muy similar a los tiempos de viaje recopilados históricamente en el mismo intervalo de tiempo. La idea básica de este tipo de métodos es encontrar los viajes anteriores bajo condiciones de tráfico similares y luego usar el tiempo de viaje histórico promedio para predecir el tiempo de viaje futuro (Ou, 2022).

Por ejemplo, para predecir el tiempo de viaje de un viaje que ocurrió el lunes a las 10:00 hs, los predictores históricos calculan el promedio de todos los datos de viajes que ocurrieron alrededor de las 10:00 hs en el pasado.

Se pueden dar algoritmos más complejos y precisos al reducir el conjunto histórico filtrando por día de la semana, mes, u otras características (C. H. Wu, Ho, y Lee, 2004).

Para la predicción a largo plazo, estos métodos suelen ser más precisos que los predictores instantáneos, ya que dependen no solo del último tiempo de viaje, sino de un promedio histórico.

3.1.3. Predictores híbridos

Este tipo de modelo combina métodos históricos e instantáneos de manera simple. Un ejemplo de esta combinación es que el predictor instantáneo se aplique para la predicción a corto plazo y el predictor histórico para la predicción a largo plazo. Diversos autores consideran que un tiempo menor a una hora para la predicción se considera corto plazo, entre ellos están [Abdollahi y cols. \(2020\)](#).

3.2. Modelos basados en la teoría del tráfico

Una segunda categoría de métodos de predicción para tiempos de viaje la forman los métodos basados en la teoría del tráfico, o flujo de tráfico.

Estos métodos predicen los tiempos de viaje basándose en modelos teóricos. Según [Mori y cols. \(2015\)](#) estos enfoques generalmente se centran en simular las condiciones del tráfico en intervalos de tiempo futuros y luego derivar los tiempos de viaje a partir del estado del tráfico predicho y los valores de las variables.

[Schwinger y cols. \(2021\)](#) detallan que estos métodos aplican relaciones entre variables de tráfico obtenidas de la teoría del tráfico y se fundamentan esencialmente en los principios de conservación y propagación del flujo.

De acuerdo a [Kumar, Vanajakshi, y Subramanian \(2017\)](#) los modelos de flujo de tráfico se pueden dividir en dos categorías principales: **modelos microscópicos** y **modelos macroscópicos**.

3.2.1. Modelos microscópicos

Los modelos microscópicos predicen los tiempos de viaje utilizando tanto matrices de origen-destino (OD) como volúmenes de giro. Las matrices OD representan el flujo de tráfico desde cada origen posible hasta cada destino. Los volúmenes de giro en vez representan el porcentaje del tráfico que gira en cada dirección en una intersección dada.

Estos modelos toman dichas representaciones como entradas y simulan las trayectorias de los vehículos individuales para los intervalos de tiempo futuros, teniendo en cuenta factores como las interacciones entre vehículos, el comportamiento del conductor, el cambio de carril, etc. Generalmente, los tiempos de viaje se pueden obtener directamente utilizando estos enfoques. Sin embargo, como mencionan [Mori y cols. \(2015\)](#), existe la tarea adicional de predecir las matrices OD y los volúmenes de giro.

3.2.2. Modelos macroscópicos

La modelización macroscópica utiliza ecuaciones que relacionan variables de tráfico agregadas como la densidad, el flujo y la velocidad media para los intervalos de tiempo futuros.

La mayoría de los estudios basados en modelos macroscópicos de flujo de tráfico desarrollaron y corroboraron sus resultados en condiciones de tráfico

homogéneas y con carriles diferenciados, tanto con datos simulados como con datos de campo (Kumar y cols., 2017).

Según Mori y cols. (2015) estos modelos generalmente no proporcionan valores de tiempo de viaje y, por lo tanto, éstos deberán inferirse mediante métodos de estimación de tiempos de viaje. Además, afirman que no son buenos para la predicción de tráfico urbano.

La principal ventaja de los enfoques basados en la teoría del tráfico según Kumar y cols. (2017), es que el modelo puede proporcionar una visión completa del estado del tráfico de la red en los dominios espacial y temporal con una cantidad limitada de datos, mientras que técnicas como aprendizaje automático o técnicas estadísticas –que veremos en la siguiente sección– requieren una mayor cantidad de datos.

Según Nithishwer y cols. (2022) estos modelos son superiores a los demás en rendimiento, debido a su capacidad para extraer información detallada sobre la ubicación y causas de diversos retrasos en una red vial.

Sin embargo, Moosavi y cols. (2023) afirman que la implementación de estos modelos requiere un profundo conocimiento de las teorías de tráfico y habilidades matemáticas y/o de programación avanzadas. Además, para predecir con precisión el tiempo de viaje utilizando este método, el flujo de tráfico simulado debe ser casi igual que la condición real, lo que es muy complicado y consume mucho tiempo.

3.3. Modelos basados en datos

Con los recientes desarrollos tecnológicos en detección automatizada del tráfico, comunicación en tiempo real, e instalaciones de cómputo de alto rendimiento, gran cantidad de datos está disponible, y esto hace que las técnicas basadas en datos sean una buena opción para la predicción del tráfico.

Según Thakkar y cols. (2021) los enfoques basados en datos utilizan la base de datos histórica y relacionan el estado actual del tráfico con los patrones históricos más similares en cuanto a los parámetros de tráfico (volumen de tráfico, flujo, velocidad, etc.).

Basándose en el análisis de patrones, la base de datos se puede clasificar en diferentes grupos como ser diferentes horas del día (horas pico y horas no pico), diferentes tipos de días (días entre semana, fines de semana, feriados), etc., y así realizar las predicciones utilizando los datos históricos.

De acuerdo a Nithishwer y cols. (2022) la principal ventaja de estos modelos es que no requieren ningún conocimiento de la teoría del tráfico y dinámica de la red. Los mismos autores mencionan que existe una amplia gama de modelos basados en datos en la literatura, como ser:

- Modelos de regresión
- Análisis de series temporales
- Modelos de búsqueda de patrones

- Árboles de regresión
- Redes neuronales artificiales
- Modelos de aprendizaje profundo

Según las técnicas de implementación de estos modelos, se pueden agrupar en tres categorías: **modelos estadísticos**, **modelos de aprendizaje automático**, y **modelos de aprendizaje profundo** (Fang y cols., 2022).

3.3.1. Modelos estadísticos

La idea principal de la predicción del tráfico en los modelos estadísticos se basa en el hecho de que los comportamientos del tráfico poseen propiedades parcialmente deterministas y parcialmente caóticas. Los resultados de la predicción se pueden obtener reconstruyendo el movimiento del tráfico determinista y prediciendo los comportamientos aleatorios causados por factores no anticipados (C. H. Wu y cols., 2004).

Los métodos estadísticos se pueden clasificar en **modelos de regresión**, y **análisis de series temporales** (Bharathi y cols., 2023).

3.3.1.1. Modelos de regresión

Los modelos de regresión asumen que el tiempo de viaje es el resultado de una función matemática con diferentes variables como ser condiciones climáticas, circunstancias del tráfico, etc. La función se utiliza para describir la relación entre la variable dependiente (el tiempo de viaje) y un conjunto de variables independientes (Ou, 2022).

En general, los modelos de regresión predicen el efecto de varios factores en el tiempo de viaje en forma de una ecuación. Además, los factores seleccionados deben tener un impacto considerable en el tiempo de viaje y ser independientes entre sí (Moosavi y cols., 2023).

Existen modelos de regresión lineal y no lineal. La regresión lineal intenta trazar una línea de mejor ajuste a través de un diagrama de dispersión¹ de los puntos registrados (Deb y cols., 2019).

Algunos de los modelos lineales son *Linear Regression (LR)*, *Ridge Regression (RR)* y *Least Absolute Shrinkage and Selection Operator Regression (LASSO)*. Los modelos de regresión no lineal se presentan dentro de la categoría de aprendizaje automático, tratado en la siguiente sección; algunos de ellos son *Regression Trees (RT)*, *Random Forest Regression (RFR)*, *Gradient Boosting Regression (GBR)* y *Support Vector Regression (SVR)*.

Ou (2022) afirma que la principal limitación de los métodos de regresión en el terreno de la predicción de tiempos de viaje es que las variables en los sistemas de transporte suelen estar inter-correlacionadas en lugar de ser completamente independientes.

¹Los diagramas de dispersión sirven para saber en qué medida una variable se ve afectada por otra. Por ejemplo representar el salario de los empleados con sus años de experiencia.

3.3.1.2. Análisis de series temporales

Dado que los tiempos de viaje de los segmentos de una ruta cambian con el tiempo, la predicción de tiempos de viaje puede considerarse un problema de predicción de series temporales. Una serie temporal es una secuencia de datos hechos en un orden temporal durante un intervalo de tiempo continuo (Fang y cols., 2022).

El análisis clásico de series temporales es uno de los métodos basados en datos más ampliamente utilizados para capturar información temporal en la predicción del tiempo de viaje. Parte del supuesto de que los valores futuros dependen de los valores históricos y de ruidos aleatorios (Wang y cols., 2023).

La predicción de series temporales utiliza modelos matemáticos para predecir valores futuros a partir de los valores observados anteriormente, teniendo en cuenta la estructura interna en los datos (He y cols., 2019).

Los modelos de series temporales más utilizados generalmente son *Autoregressive (AR)*, *Moving Average (MA)*, *Autoregressive Moving Average (ARMA)*, *Autoregressive Integrated Moving Average (ARIMA)*, *Seasonal Autoregressive Integrated Moving Average (SARIMA)* y *Kalman filter* (Ran, Shan, Fang, y Lin, 2019).

De acuerdo a Ou (2022) la precisión de este tipo de métodos depende en gran medida de la adecuación de las funciones matemáticas para modelar los datos históricos y la similitud entre los patrones de tráfico históricos y en tiempo real.

Si bien los modelos estadísticos lineales presentados en esta Sección resuelven el problema de predicción de tiempos de viaje, estos métodos no son adecuados para analizar las características no lineales de los datos de tráfico de los entornos de tráfico complejos (Fang y cols., 2022; Xu y Liu, 2021).

Es por ello que muchos investigadores se han sentido atraídos recientemente hacia los métodos de aprendizaje automático, los cuales serán tratados en la siguiente sección.

3.3.2. Modelos de aprendizaje automático

En aplicaciones donde los datos no siguen una distribución lineal, el rendimiento de los modelos lineales será muy bajo, y en esos casos, los modelos no lineales muestran mejores resultados (Ashwini y cols., 2022).

Es por eso que los investigadores en el campo de la predicción del tráfico han prestado mucha atención a los métodos de aprendizaje automático en los últimos años, debido a la capacidad de estos para modelar la compleja relación espacio-temporal no lineal en los datos de tráfico.

El aprendizaje automático se basa en la idea de que los sistemas pueden aprender de los datos y tomar decisiones. Los algoritmos de este tipo construyen modelos basándose en datos históricos y los mejoran de forma automática a través de la experiencia.

Según Ou (2022) la construcción de un modelo de aprendizaje automático comúnmente consta de cuatro fases:

1. Preparar el conjunto de datos de entrenamiento (CDE)
2. Elegir un algoritmo candidato
3. Entrenar un modelo en el CDE utilizando el algoritmo seleccionado
4. Usar y mejorar el modelo

Se han desarrollado y aplicado diversos algoritmos de aprendizaje automático en el campo de la predicción de tiempos de viaje. Los siguientes son algunos de ellos: *Support Vector Regression (SVR)*, *k-Nearest Neighbors (k-NN)*, *Regression Trees (RT)*, *Random Forest Regression (RFR)*, *Gradient Boosting Regression (GBR)*, *eXtreme Gradient Boosting (XGBoost)* y *Artificial Neural Network (ANN)*.

3.3.2.1. *Support Vector Regression (SVR)*

El objetivo principal de la Regresión de Vectores de Soporte es encontrar el mejor hiperplano en el espacio, que es un plano que puede predecir con precisión la distribución de los datos (M. Y. Chen y cols., 2022).

La idea básica es encontrar una fórmula que pueda predecir adecuadamente los valores futuros minimizando el error e identificando el hiperplano que optimiza el margen. SVR utiliza una fórmula para mapear los datos de entrenamiento desde el espacio de entrada hacia un espacio de dimensiones superiores, y luego se crea un hiperplano separativo en el espacio de características con el margen máximo (Khaled y cols., 2022).

Una de las principales ventajas de SVR según Awad y Khanna (2015) es que su complejidad computacional no depende de la dimensionalidad del espacio de entrada. Además, afirman que tiene una excelente capacidad de generalización, con alta precisión en la predicción.

3.3.2.2. *k-Nearest Neighbors (k-NN)*

La regresión de k-Vecinos Más Cercanos también se conoce como un “aprendiz perezoso”. Es un modelo no lineal básico que funciona según el principio de similitud. Estima la diferencia entre las instancias del conjunto de entrenamiento y las instancias del conjunto de prueba utilizando la distancia (normalmente euclídeana). Cuanto menor sea la distancia, mayor será la similitud entre las instancias. (Ashwini y cols., 2022).

Los modelos basados en el algoritmo de regresión k-NN deducen el valor de la variable objetivo (tiempo de viaje) en función de la similitud con el vecino más cercano. Éste es un enfoque popular para elegir viajes similares.

Al comienzo se debe definir un k para representar la complejidad del modelo durante el entrenamiento. Este valor indica que los datos de prueba necesitarán encontrar los k puntos más cercanos a sí mismos e identificar el mejor resultado a través de un proceso iterativo continuo (M. Y. Chen y cols., 2022).

El k-NN es un algoritmo que no hace ninguna suposición sobre los datos subyacentes, tampoco utiliza ningún dato de entrenamiento explícito para hacer

generalizaciones, o es muy mínimo (Nithishwer y cols., 2022). La suposición básica de este modelo es que los objetos de datos en cada clase están distribuidos de manera consistente, pero para esto el valor de k debe elegirse cuidadosamente.

Según Ou (2022) determinar el tamaño óptimo de los vecinos más cercanos es muy complicado, y éste influye en gran medida en el rendimiento de la predicción. Awad y Khanna (2015) detallan que un valor muy pequeño puede resultar en un comportamiento ruidoso, mientras que un valor muy grande puede incluir demasiados puntos de otras clases.

Por otro lado, Putatunda y Laha (2023) mencionan que este método es computacionalmente costoso para conjuntos de datos de entrenamiento grandes. Su fundamento es que es una técnica basada en la memoria y no tiene costo de entrenamiento ya que todo el conjunto de datos de entrenamiento se mantiene en la memoria y se usa para encontrar similitudes con las instancias de prueba. Esto hace que el método tenga problemas relacionados con la velocidad o la memoria, especialmente cuando el tamaño del conjunto de datos de entrenamiento es grande.

3.3.2.3. *Regression Trees (RT)*

Un Árbol de Regresión, comúnmente conocido como árbol de decisión, es un modelo de aprendizaje automático no lineal aplicado para predecir una variable continua. En los modelos basados en árboles, no hay ecuaciones matemáticas para demostrar la relación entre múltiples variables, sino que se busca construir un modelo que pronostique la variable objetivo aprendiendo a través de reglas simples a partir de los datos de entrenamiento (Ashwini y cols., 2022).

En la Figura 3.2 se aprecia un árbol de decisión de profundidad 2, donde la característica “día de la semana” con el valor “fin de semana” se elige como primer punto de división. Los dos nodos subsecuentes dividen el espacio de características en las observaciones que pertenecen a los fines de semana (nodo izquierdo) y todos los demás días (nodo derecho). Luego, la variable “hora del día” con el valor de la característica “7 am” se elige para dividir los datos pertenecientes a los fines de semana produciendo dos hojas con los valores finales de predicción (12,5 minutos, y 7,4 minutos). Análogamente para la rama de la derecha, la característica “llueve” divide nuevamente en dos hojas de predicción (27,1 minutos, y 22,3 minutos).

A diferencia de algunos métodos de aprendizaje automático que funcionan como cajas negras, RT puede proporcionar resultados interpretables y revelar relaciones no lineales entre las variables (Qiu y Fan, 2021).

Los árboles de decisión suelen tener un buen rendimiento predictivo en los CDE, pero demasiadas divisiones pueden provocar un sobreajuste y un rendimiento deficiente en los conjuntos de prueba (N. Li y cols., 2023).

Con el objetivo de mejorar el rendimiento de predicción se puede entrenar múltiples modelos RT simultáneamente y combinar su poder predictivo. A este tipo de enfoque se le llama *Ensemble Learning*, o Aprendizaje por Conjunto (Ahmed y cols., 2022).

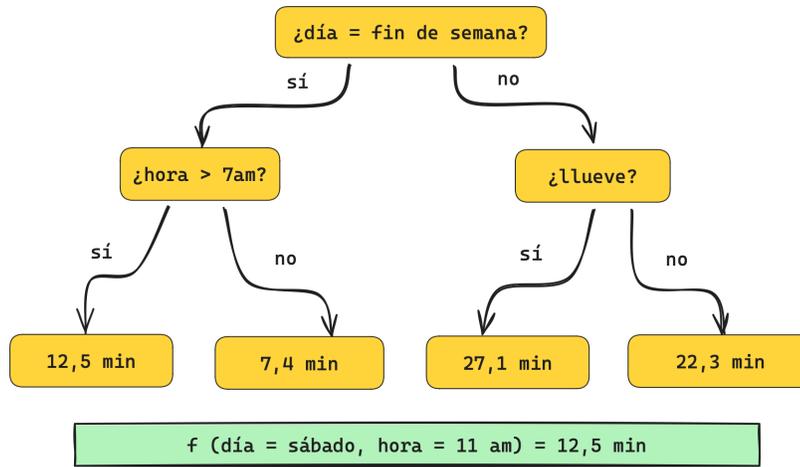


Figura 3.2: Árbol de decisión de profundidad 2. Fuente: elaboración propia.

En el área de predicción de tiempos de viaje, los modelos más utilizados de aprendizaje por conjunto basado en árboles son *Random Forest Regression* (**RFR**), *Gradient Boosting Regression Tree* (**GBRT**), y *eXtreme Gradient Boosting* (**XGBoost**).

3.3.2.4. *Random Forest Regression* (RFR)

Este método consiste en generar múltiples modelos RT, cada uno de los cuales proporciona una solución alternativa al problema. La diversidad entre los modelos tiende a hacer que los resultados de predicción sean más precisos. Según afirman [H. Huang y cols. \(2020\)](#), un único RT siempre sufre de una alta varianza, lo que puede causar inestabilidad en los resultados de predicción.

Cada árbol se construye aplicando un algoritmo particular sobre el CDE y un vector aleatorio adicional, que se muestrea de forma independiente e idénticamente distribuida, de manera que cada muestra tenga la misma probabilidad de ser seleccionada.

Según [Ashwini y cols. \(2022\)](#) el método RFR obtiene predicciones estables y precisas al construir múltiples árboles de regresión y combinar los resultados de cada árbol. La predicción del bosque aleatorio se obtiene mediante una votación mayoritaria sobre las predicciones de los árboles individuales.

En la Figura 3.3 se aprecia un ejemplo de RFR con cantidad de muestreo tres. A modo de simplificación, cada muestra extrae aleatoriamente solo una característica. También se observa el resultado de la función combinando las predicciones de los tres árboles.

Debido al procedimiento de selección aleatoria de características y muestras de entrenamiento, se ha demostrado que RFR es eficiente para evitar el sobreajuste ([C. Chen y cols., 2020](#)). Además el método se comporta óptimamente en conjuntos

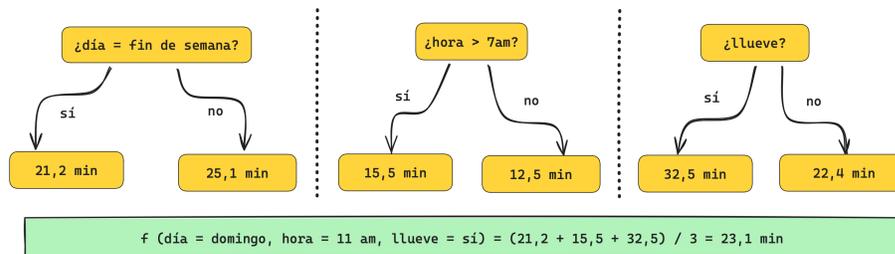


Figura 3.3: RFR con cantidad de muestreo 3. Fuente: elaboración propia.

de datos grandes (Deb y cols., 2019). Sin embargo, en presencia de ruido, el proceso de entrenamiento puede llevar más tiempo (N. Li y cols., 2023).

3.3.2.5. Gradient Boosting Regression (GBR)

El Árbol de Regresión por Impulso del Gradiente es otro modelo de aprendizaje por conjunto similar al RFR. Sin embargo a diferencia de éste, no se utilizan árboles profundos y CDE diferentes en GBR. Se construyen árboles poco profundos que se entrenan en el mismo conjunto de datos, pero cada árbol está especializado en una característica específica (Moosavi y cols., 2023).

El concepto de impulso (boosting) surge de la idea de que un aprendiz deficiente puede ser modificado para convertirse en un aprendiz mejor. Para esto se entrenan árboles sucesivos en serie con el objetivo de que el árbol n-ésimo corrija los errores de predicción de los árboles anteriores.

El criterio de parada de este ciclo iterativo se da cuando se alcanza un error de umbral, cercano a cero. De esta manera, GBR combina múltiples árboles de decisión y acumula los resultados de salida de todos para finalmente producir un único árbol de regresión mejorado (M. Y. Chen y cols., 2022).

3.3.2.6. eXtreme Gradient Boosting (XGBoost)

XGBoost es un modelo de aprendizaje automático de vanguardia (Chughtai, Haq, y Muneeb, 2022) que al igual que RF y GBR, utiliza un conjunto de árboles de decisión para predecir el tiempo de viaje. Sin embargo XGBoost utiliza el impulso de gradiente para ponderar los aprendices débiles. Además, las diferentes muestras tienen una probabilidad diferente de aparecer en modelos posteriores, y las muestras con la tasa de error más alta aparecerán más veces. Esto garantiza que las muestras incorrectamente estimadas o mal clasificadas tengan una mayor probabilidad de ser seleccionadas, para corregir los errores (Qiu y Fan, 2021).

Según N. Li y cols. (2023) XGBoost propone tres ventajas principales frente a GBR:

1. Mejora la precisión del modelo.
2. Evita la complejidad del modelo previniendo el sobreajuste.

3. Aumenta la velocidad de cálculo del modelo.

Debido a estas ventajas, XGBoost tiene una excelente estabilidad, precisión y velocidad de convergencia en la predicción. Además, [Qiu y Fan \(2021\)](#) detallan que XGBoost es robusto a los valores atípicos, por lo que se considera que tiene un buen rendimiento en predicciones relacionadas con series temporales. Por otro lado, según [Katayama y cols. \(2022\)](#) este método logra una alta precisión en la interpolación de objetivos correlacionados espacialmente si se utiliza la latitud y longitud como entradas.

Sin embargo, a pesar de que XGBoost ha presentado un rendimiento dominante en muchas competiciones de aprendizaje automático e inteligencia artificial aplicadas ([H. Huang y cols., 2020](#)), es un método que puede manejar datos únicamente estructurados como Tablas. [Shen y cols. \(2022\)](#) tuvieron que re-muestrear uniformemente cada trayectoria –secuencia de datos– a una longitud fija. Los mismos autores afirman que este proceder perdería la relación espacio-temporal de los datos originales. Es posible que se eliminen puntos temporales importantes o que se agreguen puntos artificiales que no estaban presentes en la secuencia original. Esta limitación no existe en los modelos basados en aprendizaje profundo que se detallan en la siguiente sección.

Concluyendo con los métodos de aprendizaje por conjunto basado en árboles, éstos presentan las siguientes ventajas según [H. Huang y cols. \(2020\)](#):

- Robustez frente a la correlación lineal de características.
- Robustez frente a la alta dimensionalidad.
- Facilidad para el entrenamiento.
- Baja carga computacional en general.

Sin embargo, a medida que aumenta el volumen de datos, el rendimiento de estos modelos comienza a deteriorarse ([Chughtai, Haq, y Muneeb, 2022](#)), y para mejorar este aspecto se puede utilizar una combinación de varios algoritmos para la predicción de tiempos de viaje. Comúnmente se combinan con técnicas de redes neuronales, cuyas bases se describen a continuación.

3.3.2.7. Artificial Neural Network (ANN)

La Red Neuronal Artificial (ANN) es también un algoritmo popular de aprendizaje automático para la predicción del tiempo de viaje. Está inspirada en las redes neuronales biológicas, por lo que cuenta con múltiples capas de unidades de procesamiento llamadas neuronas artificiales. Cada neurona tiene una función de activación y está conectada con otras neuronas. La conexión entre dos neuronas significa que la salida de una neurona es la entrada de otra neurona. Además, a cada conexión se le asigna un peso que representa su importancia.

A través del proceso de aprendizaje, los pesos iniciales se ajustan para capturar la relación entre las entradas y las salidas, generalmente mediante

un algoritmo de retropropagación. Los métodos basados en ANN han ganado popularidad en la predicción del tiempo de viaje debido a su capacidad para resolver relaciones no lineales complejas (Ou, 2022).

En las últimas dos décadas, investigadores en diferentes campos han aplicado diferentes tipos de redes neuronales en el campo de la predicción del tráfico utilizando el método ANN.

Sin embargo, estas redes han sido afectadas por una serie de desafíos y limitaciones. Entre ellos la llamada maldición de la dimensionalidad (Awad y Khanna, 2015), que ocurre cuando el número de características y puntos de entrenamiento se vuelve significativamente grande. Los grandes conjuntos de datos hacen que el aprendizaje de las ANN sea más difícil, sumado a la abrumadora cantidad de datos para procesar y los requisitos de memoria y/o computacionales.

Otro desafío es la no linealidad de los datos que existe cuando hay superposición de características en diferentes clases, lo que hace que la predicción de tiempos de viaje sea más difícil en estos escenarios.

Concluyendo esta sección, los métodos de aprendizaje automático mejoran la precisión de la predicción de tiempos de viaje en comparación con los métodos estadísticos. Además aportan simplicidad, eficiencia e interpretabilidad según L. Zhang y cols. (2021).

Sin embargo, el principal defecto de los métodos de aprendizaje automático es la contradicción entre la estructura superficial y los datos de tráfico a gran escala (Wang y cols., 2023).

Por otro lado, es difícil modelar con precisión el impacto que tendrán los eventos repentinos (accidentes, construcción, control, etc.) en la predicción del tiempo de viaje (L. Zhang y cols., 2021); estos métodos se enfocan principalmente en la parte temporal de los datos e ignoran las dependencias espaciales (Khaled y cols., 2022; Alkilane y cols., 2023).

Por último y no menor, generalmente solo predicen el tiempo de viaje dentro de un cierto período (como el período fuera de horas pico). En cambio, para los datos de tiempo de viaje con gran aleatoriedad, fluctuaciones y mecanismos complejos, el rendimiento de predicción probablemente sea mediocre o incluso pobre (L. Zhang y cols., 2021).

3.3.3. Modelos de aprendizaje profundo

Con el desarrollo del aprendizaje profundo, las redes neuronales profundas han demostrado tener la profundidad suficiente para procesar datos de alta dimensionalidad a gran escala. Debido a su flexibilidad, se han propuesto diferentes estructuras para la predicción del tiempo de viaje.

Las arquitecturas de aprendizaje profundo tienen como objetivo aprender de manera jerárquica, acumular conocimiento a medida que la información se propaga a través de niveles superiores, de manera que el aprendizaje en el nivel

superior se basa en el aprendizaje estadístico que ocurre en las capas de nivel inferior.

En los últimos años se han propuesto diversos enfoques de aprendizaje profundo, como lo son *Multi-Layer Perceptron* (**MLP**), *Recurrent Neural Network* (**RNN**), *Long Short-Term Memory* (**LSTM**), *Gated Recurrent Unit* (**GRU**), Mecanismos de Atención, *Convolutional Neural Network* (**CNN**), *Graph Neural Network* (**GNN**), etc.

Los resultados experimentales muestran que estos enfoques de aprendizaje profundo superan ampliamente a los métodos basados en estadísticas y en aprendizaje automático (Nithishwer y cols., 2022). Sin embargo, estas técnicas requieren un costo computacional relativamente alto (C. H. Chen, Hwang, y Kung, 2019).

3.3.3.1. *Multi-Layer Perceptron* (MLP)

El perceptrón multicapa es el tipo de red neuronal más común y simple, ampliamente utilizado para predicción de tiempos de viaje, así como para procesos de reconocimiento de patrones. Es una ANN que consta de múltiples capas de nodos completamente conectados por un grafo dirigido, en el cual cada nodo (excepto los nodos de entrada) es una neurona con una función de activación no lineal.

El MLP consta de al menos tres capas de neuronas, incluyendo una capa de entrada, una o más capas ocultas, y una capa de salida. El número de neuronas de entrada depende de las dimensiones de las características de entrada (por ejemplo características temporales, espaciales, climáticas, etc.); el número de neuronas de salida está determinado por el número de clases existentes (por ejemplo tráfico ligero, moderado, pesado, etc.); el número de capas ocultas y el número de neuronas en cada capa oculta dependen del tipo de problema que se está resolviendo. Según Awad y Khanna (2015) un número pequeño de neuronas resulta en un aprendizaje ineficiente, mientras que un número mayor resulta en una generalización ineficiente.

Tanto MLP como ANN tienden a recordar fácilmente dependencias a largo plazo, lo que seguirá afectando el aprendizaje actual y futuro. Por lo que si se requiere predecir los tiempos de viaje en tiempo real, se necesita controlar la exposición del contenido de la memoria y actualizarlo constantemente (C. Y. Chen y cols., 2023).

Por otro lado, aunque este método funciona bien en tareas de predicción de tiempo de viaje a corto plazo, no consigue captar las correlaciones entre los distintos enlaces de las rutas ni la memoria del proceso de viaje (Wang y cols., 2023).

Para superar estas limitaciones se propuso una red neuronal especial denominada *Recurrent Neural Network* (RNN), que mejora la memoria de los datos secuenciales computando y combinando repetidamente la información oculta en diferentes marcas de tiempo.

3.3.3.2. *Recurrent Neural Network (RNN)*

A diferencia de MLP que es una red neuronal *feed-forward*², las RNN poseen conexiones retroalimentadas que le permiten mantener y utilizar la información de estados anteriores.

Es por esta cualidad que son ampliamente utilizadas para capturar las dependencias temporales en el aprendizaje secuencial, ya que pueden “memorizar” el historial en la secuencia procesada. Además, también consideran las relaciones entre las salidas históricas y las entradas actuales (Fang y cols., 2022).

Sin embargo, a medida que la longitud de la secuencia de entrada aumenta, las RNN estándar sufren de dos problemas conocidos en aprendizaje profundo: el gradiente explosivo y el desvanecimiento de gradiente. Según C. Y. Chen y cols. (2023) la explosión de gradientes es relativamente fácil de manejar y se puede resolver limitando el gradiente mediante el establecimiento de un umbral. En cambio el efecto de desvanecimiento del gradiente es mucho más difícil de resolver, lo que reduce la capacidad de la red para capturar dependencias a largo plazo.

Para superar estas limitaciones se desarrollaron dos variantes especializadas de las RNN: *Long Short-Term Memory (LSTM)* y *Gated Recurrent Unit (GRU)*. Estos modelos utilizan el mecanismo de puertas para manejar secuencias de series temporales a largo plazo.

3.3.3.3. *Long Short-Term Memory (LSTM)*

En comparación con la RNN estándar, LSTM utiliza 3 puertas, de las cuales una puerta de entrada y una puerta de olvido se utilizan para controlar el flujo de información de entrada/salida. Estas puertas permiten que LSTM retenga información importante y filtre la información no importante, lo que mitiga eficazmente los problemas de desvanecimiento y explosión del gradiente (K. Zhang y cols., 2020).

LSTM ha sido aplicado con éxito en la predicción del tiempo de viaje y la velocidad de los vehículos, e incluso según Fang y cols. (2022) LSTM de múltiples capas estimó eficazmente las condiciones del tráfico.

3.3.3.4. *Gated Recurrent Unit (GRU)*

El modelo GRU es una red neuronal que se mejoró a partir de LSTM. Dado que el modelo LSTM es muy complejo, el modelo GRU tuvo la intención de reducir la complejidad fusionando la puerta de entrada y la puerta de olvido del modelo LSTM en una puerta de actualización, y cambiando la puerta de salida por una puerta de reinicio. Al mismo tiempo, el estado de la unidad y la salida se fusionan en un parámetro de estado único.

Como mencionan Jakteerangkool y Muangsin (2020), el hecho de que el número de puertas cambie de tres a dos, provoca que se reduzcan los parámetros de entrenamiento, y por consecuencia que se aumente la velocidad de entrenamiento.

²En las redes *feed-forward* cada capa procesa la información y la pasa a la siguiente capa sin que la información vuelva a las capas anteriores.

Tanto LSTM como GRU han sido adoptados para manejar el problema de predicción de tiempos de viaje, pudiendo capturar las dependencias temporales en el aprendizaje secuencial. Sin embargo, la correlación espacial de la red de tráfico no se puede transformar en datos secuenciales de baja dimensionalidad (Wang y cols., 2023), y los métodos basados en RNN apenas pueden capturar la dependencia espacial en el campo del tráfico. Una solución para esto es incorporar modelos de *Convolutional Neural Network* (CNN), que se tratan en las siguientes secciones.

Por otro lado, Chughtai, Haq, y Muneeb (2022) afirman que los métodos basados en RNN tienen dificultades para modelar implícitamente el contexto en secuencias históricas de tiempo de viaje. Esto debido a que asignan pesos iguales a todos los estados ocultos cuando se utilizan para la tarea de predicción de tiempos de viaje. Para solucionar esto, los autores proponen utilizar mecanismos de atención, que tengan como objetivo volver a ponderar los pesos de la red aprovechando la relación oculta entre posiciones distintas en la secuencia de tiempo de viaje.

Otra limitación que presentan las RNN es que están limitadas a procesar datos consecutivos uno tras otro, lo que restringe los cálculos paralelos, y por lo tanto la eficiencia (Alkilane y cols., 2023).

Tras estos puntos, es claro que existe una debilidad al utilizar modelos únicamente basados en RNN, es por ello que se propusieron modelos de aprendizaje profundo basados en la combinación de RNN y CNN, típicamente LSTM-CNN, ConvLSTM, etc.

3.3.3.5. Mecanismos de Atención

Los mecanismos de atención han tenido éxito en muchas tareas, como ser la clasificación de imágenes, el procesamiento de lenguaje natural, la traducción automática neuronal, la recomendación multimedia, etc. Debido a este éxito se han introducido recientemente en la predicción del tiempo de viaje.

La idea principal de estos mecanismos es concentrarse en las diferencias entre las características de entrada y aprender solo el contexto relevante. Según Ran, Shan, Fang, y Lin (2019) el mecanismo de atención suele implementarse mediante la construcción de una red de mirada, que es una red neuronal de dos capas que se entrena junto con el modelo principal.

Esta red permite enfocar ciertas partes de una entrada, dándoles más importancia durante el procesamiento. Esto puede ser útil en tareas donde ciertas partes de la entrada sean más relevantes que otras, permitiendo al modelo centrarse en esas áreas para tomar decisiones más certeras.

Los mecanismos de atención o modelos basados en atención han demostrado ser modelos muy potentes y adaptables en una amplia gama de aplicaciones de transporte (Chughtai, Haq, Shafiq, y Muneeb, 2022).

3.3.3.6. *Convolutional Neural Network (CNN)*

Al igual que con los mecanismos de atención, el éxito de las Redes Neuronales Convolucionales en el procesamiento de imágenes hizo que algunos investigadores las aplicaran para aprender el tráfico como imágenes. Dado que la red de tráfico puede transformarse fácilmente en imágenes, este enfoque ha sido adoptado recientemente para capturar las características espaciales (Fang y cols., 2022).

Los modelos CNN se propusieron mejorar la capacidad de aprendizaje de las redes neuronales aprovechando la topología de los datos de entrada. Esta red combina tres ideas arquitectónicas: campos receptivos locales, pesos compartidos y submuestreo espacial o temporal.

Múltiples investigaciones confirmaron que estos modelos pueden mejorar la precisión predictiva cuando son aplicados al tráfico (Ran, Shan, Fang, y Lin, 2019; Ran, Shan, Shi, y Lin, 2019; X. Li y cols., 2021; Fan y cols., 2021). Sin embargo, la estructura real de la red vial es no euclidiana según afirman Xu y Liu (2021), y la estructura de cuadrícula bidimensional no puede modelar la correlación topológica de las redes viales complejas. Para estos escenarios existe un modelo más idóneo que es *Graph Neural Network (GNN)*.

3.3.3.7. *Graph Neural Network (GNN)*

En los últimos años, las Redes Neuronales de Grafos han recibido una creciente atención para la predicción del tiempo de viaje. Dado que la red de tráfico es naturalmente un grafo, las GNN han sido utilizadas para aprender las características espaciales de la red.

Considerando los enlaces en la red de carreteras como nodos con relaciones de conexión, la red de carreteras podría transformarse fácilmente en una estructura de grafo. Un ejemplo típico de estos modelos son las *Graph Convolutional Network (GCN)*, que se han aplicado extensamente en la predicción de tiempos de viaje y en otras predicciones de tráfico (Fang y cols., 2022).

Recientemente, los modelos de GNN han mostrado un rendimiento de vanguardia según Chughtai, Haq, Shafiq, y Muneeb (2022), y sus aplicaciones en los problemas de tráfico incluyen predicción de tiempos de viaje, predicción del estado del tráfico, predicción del flujo de tráfico, predicción de la demanda de viajes, predicción de trayectorias, etc.

Sin embargo, si bien los métodos basados en GNN son capaces de aprender la estructura topológica de las redes de tráfico y realizar predicciones precisas, los grandes modelos de aprendizaje profundo que utilicen este enfoque consumirán enormes recursos computacionales, lo que es algo no despreciable y a tener en cuenta (Fang y cols., 2022).

Concluyendo este Capítulo, se ha mostrado que existe una amplia gama de enfoques para modelar la predicción del tiempo de viaje, desde los modelos más simples y basados en suposiciones ingenuas hasta los modelos más complejos basados en el aprendizaje profundo.

Los modelos ingenuos proporcionan predicciones simples y rápidas del tiempo

de viaje, pero pueden carecer de precisión debido a su simplicidad; por lo general se utilizan para comparar con otros métodos.

Los modelos basados en la teoría del tráfico se centran en simular las condiciones del tráfico en intervalos de tiempo futuros para derivar los tiempos de viaje. Como ventaja, proporcionan una visión completa del estado del tráfico con una cantidad limitada de datos. Como desventaja, requiere un profundo conocimiento de las teorías de tráfico y habilidades matemáticas y/o de programación avanzadas.

Los modelos basados en datos pueden clasificarse en modelos estadísticos, modelos de aprendizaje automático y modelos de aprendizaje profundo.

Los modelos estadísticos emplean patrones deterministas y caóticos del tráfico para predecir el tiempo de viaje. Pueden estar limitados a captar únicamente correlaciones lineales, pero su simplicidad justifica su uso.

Los modelos de aprendizaje automático se basan en algoritmos que aprenden de los datos históricos para hacer predicciones. Éstos logran tener mejor precisión que los estadísticos, pudiendo captar las relaciones no lineales, y presentando la virtud de ser fácilmente interpretables. Como contrapartida, normalmente pueden captar solo las relaciones temporales ignorando las espaciales. Además frente a grandes cantidades de datos su rendimiento por lo general se ve afectado.

Los modelos de aprendizaje profundo se basan en redes neuronales que pueden tener memoria y entender el contexto, presentando un mejor desempeño en el manejo de las complejidades y no linealidades de los datos. Las RNN han mostrado resultados prometedores para captar las características temporales, mientras que CNN y GNN se especializan en capturar las dependencias espaciales.

La combinación entre varios enfoques hace que el aprendizaje profundo presente una precisión inigualable, sin embargo su baja interpretabilidad, altos costos de entrenamiento y gran complejidad hace que los desafíos aumenten.

En resumen, cada enfoque tiene sus ventajas y limitaciones y es difícil decir qué modelo es mejor para cada escenario, ya que su elección depende de factores como la disponibilidad de datos, la complejidad del problema, los niveles de precisión que se admitan y los recursos computacionales disponibles.

Capítulo 4

Clasificación de Predicción de Tiempos de Viaje

En este Capítulo se analiza la predicción de tiempos de viaje en diferentes contextos, según el tipo de vehículo para el que se quiere predecir y según el entorno en el que se intente predecir. Asimismo, se presentan algunos de los trabajos recuperados en relación con cada clasificación.

4.1. Clasificación según el tipo de vehículo

Existe una gran variedad de tipos de vehículo, y cada predicción debe contemplar las condiciones a las que está sometido cada tipo. A continuación se mencionan los principales tipos de vehículo estudiados en el problema de predicción de tiempos de viaje.

4.1.1. Vehículo particular

El caso del vehículo particular, es quizás el tipo de predicción más habitual, en él se establece la ruta de acuerdo al par origen-destino. Los vehículos particulares no siguen rutas fijas ni horarios predecibles, sino que están influenciados por las preferencias individuales de los conductores.

A continuación se presentan algunos estudios que han abordado TTP para vehículos particulares mediante diferentes enfoques metodológicos, tanto en lo que refiere al tipo de datos utilizado, como al mecanismo de predicción en sí.

[Katayama y cols. \(2022\)](#) estudian la densidad de tráfico como posible insumo para detectar embotellamiento de tráfico y predecir tiempos de viaje. En particular, los autores sostienen que mientras no exista embotellamiento, la velocidad puede servir de insumo para calcular la predicción de tiempos de viaje, pero una vez éste aparece, ya no es posible considerarla como parámetro fidedigno. En vez, la densidad de tráfico sirve tanto cuando existe embotellamiento como cuando no. El trabajo se centra en carreteras de Dakota del Sur, Estados Unidos, y los

autores logran tener una buena precisión de la densidad de tráfico a partir de una interpolación espacial.

[Chughtai, Haq, y Muneeb \(2022\)](#) proponen un modelo de red neuronal GRU basado en atención para la predicción del tiempo de viaje a corto plazo (horizonte máximo de 60 minutos), permitiendo que la GRU aprenda el contexto relevante en las secuencias históricas de tiempo de viaje y logre de esta manera una mejor precisión en la predicción. Los autores evalúan el modelo propuesto utilizando datos obtenidos con la tecnología *Floating Card Data*(FCD) de vehículos de Beijing, China.

Los mismos autores en [Chughtai, Haq, Shafiq, y Muneeb \(2022\)](#) afirman que el tiempo de viaje se ve influenciado por diversos factores como el clima y las horas pico, lo que exige un modelo múltiple para capturar las no linealidades en los datos de tráfico y así lograr una predicción precisa del tiempo de viaje. Ellos desarrollan un novedoso modelo de conjunto de predicción del tiempo de viaje basado en el Espacio de Características Profundas Híbridas, que adopta una estrategia de aprendizaje de características híbridas. Este trabajo tomó los datos de Zhangzhou, China.

[Elmi y Tan \(2020\)](#) se enfrentan a la tarea de predecir el tiempo de viaje de áreas donde hay pocos datos históricos de tráfico disponibles, lográndolo utilizando lo que los autores llaman un marco de aprendizaje por transferencia, que explota los datos históricos de algunas áreas de origen que son regiones ricas en datos. Utilizan una arquitectura híbrida que modela la cercanía espacial y temporal (de los puntos origen-destino), así como la tipología de la red vial. Los datos son sacados de la red de carreteras de New York, Estados Unidos.

4.1.2. Taxi y ride-hailing¹

El problema de la predicción para taxis y/o servicio ride-hailing (ej. Uber, Cabify, Didi, etc.) es similar al de vehículo particular desde el punto de vista de escoger una ruta óptima dado un origen y un destino variables. Sin embargo, al considerar que estos son un medio de empleo para los ciudadanos, se puede observar que los conductores de estos medios demuestran patrones de conducta diferentes al conductor no profesional ([J. Wu, 2014](#)).

En los últimos años el problema de TTP para taxis ha sido estudiado ampliamente, a continuación se brindan algunos de los estudios relacionados.

[Putatunda y Laha \(2023\)](#) estudian el problema de predicción del tiempo de viaje para taxis en diferentes escenarios y proponen un sistema de alerta de exceso de velocidad en tiempo real, y una tarjeta de puntuación de conductor sospechoso de exceso de velocidad. Esto tiene un gran potencial para mejorar la seguridad del viaje.

[Deb y cols. \(2019\)](#) proponen un enfoque para predecir el nivel de congestión del tráfico en función de un análisis de series temporales de datos recopilados utilizando aprendizaje automático. El modelo de predicción está diseñado específicamente para automóviles sedán y modelos similares a taxis. Los autores

¹Se denomina servicios de ride-hailing a las empresas que organizan viajes en vehículos privados conducidos por sus propios dueños a cambio de una tarifa.

dejan claro que su solución aplica a esos modelos de vehículos, y que otros modos de transporte pueden tener diferentes tiempos de viaje en comparación con los predichos por su modelo. Los datos de tráfico utilizados fueron recopilados de Uber Movement para la ciudad de Mumbai, India.

Wang y cols. (2023) proponen un modelo de aprendizaje profundo basado en redes neuronales de grafos y redes neuronales recurrentes para la predicción del tiempo de viaje. A diferencia de los estudios anteriores, los autores utilizan una red neuronal de grafos para capturar la correlación espacial, una red neuronal recurrente para capturar la información temporal y también un modelo específico para extraer información exógena. Los datos fueron tomados de Didi, en la ciudad de Chengdu, China.

H. Huang y cols. (2020) utilizan métodos de ensamble basados en árboles para predecir los tiempos de viaje entre dos puntos arbitrarios, abarcando dos perspectivas temporales: pronósticos a largo plazo con un horizonte de varios días y pronósticos a corto plazo con un horizonte de una hora. El conjunto de datos los extrae de registros de viajes en taxi de la ciudad de Nueva York. Como era de esperar, las predicciones a corto plazo fueron ligeramente mejores que las predicciones a largo plazo. Además, los autores demuestran que se pueden obtener buenas predicciones a corto plazo con solo un poco de datos de entrenamiento, y concluyen que la duración del viaje tiene una memoria bastante corta y depende principalmente de los viajes de la última hora.

Fiosina (2021) predice el tiempo de viaje de los taxis de Brunswick, Alemania, basándose en trayectorias de datos de automóviles en movimiento obtenidas de diferentes proveedores de servicios de taxi, los cuales deben mantenerse privados. Debido a este último requerimiento, propone un enfoque de aprendizaje federado² que ayuda a procesar estos datos de manera distribuida, considerando las preocupaciones de privacidad. El autor utiliza una arquitectura basada en aprendizaje profundo, que a su juicio si bien estos modelos son más precisos que otros modelos de aprendizaje automático, son modelos de caja negra, intransparentes y no explicables, que deben explicarse tanto para los usuarios como para los desarrolladores. Para solucionar esta debilidad, consigue un enfoque de aprendizaje federado horizontal explicativo, que permite procesar los datos distribuidos mientras se adhieren a su privacidad, e investigar cómo los métodos de explicación de modelos de vanguardia pueden explicarlo.

4.1.3. Transporte público colectivo

Según K. Zhang y cols. (2020) hay métodos que permiten predicciones relativamente precisas para taxis o autos privados, pero no son muy efectivos para los autobuses, un ejemplo de estos métodos es ARIMA. Debido a que los autobuses siguen una ruta fija y necesitan detenerse en varias paradas, el tiempo de permanencia en cada parada tiene una gran influencia en el tiempo de viaje total, afirman los autores. Esto hace que el uso de métodos frecuentes para

²El enfoque federado es una estrategia del aprendizaje automático que permite a varios clientes participantes conservar sus datos de entrenamiento de forma local mientras entrenan un modelo general compartido.

predecir el tiempo de viaje de los taxis y/o autos privados lleve a resultados inexactos en el contexto de transporte público colectivo. Como alternativa de ARIMA, un método estadístico que sí funciona en este contexto es *Kalman Filter*, que se utiliza frecuentemente (Ashwini y cols., 2022).

Schwinger y cols. (2021) realizan un estudio para el transporte público en Aachen, Alemania, donde utilizan datos históricos y también información en tiempo real, y afirman que conviene combinar los algoritmos de aprendizaje automático con *Kalman Filter* para obtener una mejora en la precisión. Si bien el enfoque que le dieron es para predicciones a corto plazo, afirman que lo probaron a largo plazo y también se comporta adecuadamente.

Según Moosavi y cols. (2023) no hay un único modelo de aprendizaje automático que sea el más preciso en la predicción del tiempo de viaje en autobús, especialmente en lo que respecta a la frecuencia del servicio de autobús. Los autores realizaron un trabajo de investigación en la ciudad de Kuala Lumpur, Malasia, utilizando técnicas de aprendizaje automático basadas en árboles. Ellos afirman que existen diferencias significativas entre las rutas de autobús de alta frecuencia y de baja frecuencia, y la precisión de la predicción está relacionada con la frecuencia del servicio. En su experimento, comparan GBR, RF y un modelo de árboles llamado *Chi-square Automatic Interaction Detection* (CHAID), y concluyen que el modelo GBR es preferible para rutas de alta frecuencia, mientras que CHAID funciona mejor en rutas de baja frecuencia.

Mendes-Moreira y Baratchi (2020) proponen un método llamado *Reconciliation for Regression* (R4R) basado en reconciliación³ para la predicción de tiempos de viaje de ómnibus, que opera en 2 pasos. En el primer paso, se predicen los tiempos de viaje de los enlaces entre paradas de autobús consecutivas, y en el segundo paso se reconcilian estas predicciones individuales para calcular el tiempo total de viaje. Los autores afirman que el método R4R mejora el rendimiento general tanto en la predicción como en la reconciliación. Además sugieren que este método puede generalizarse a otros dominios más allá de la predicción del tiempo de viaje en ómnibus. Los datos fueron sacados de un conjunto de datos reales de la ciudad de Oporto, Portugal.

C. Chen y cols. (2020) motivados por la frustración de los pasajeros al esperar en las paradas de colectivos, estudian el problema de predicción de tiempos de viaje para autobuses y comparan métodos de predicción típicos como k-NN, ANN, RF y SVR contra un método propio que sigue el enfoque de aprendizaje profundo. En su experimento con datos tomados de Shenyang, China, demuestran que su algoritmo funciona mejor.

K. Zhang y cols. (2020) detectan que no hay muchos estudios relativos al transporte público colectivo sobre cómo dividir las áreas de espera y de tránsito, y de cómo construir modelos independientes para ellos. Es por esto que se embarcan en proponer un marco de aprendizaje profundo de extremo a extremo para la predicción del tiempo de viaje en autobús donde el camino objetivo es de longitud arbitraria. Adoptan dos componentes espacio-temporales independientes

³La idea de reconciliación de predicciones en series temporales se ha propuesto para proporcionar predicciones óptimas, modelando las series temporales colectivamente en lugar de hacerlo por separado en cada nivel.

que utilizan CNN en una dimensión (a diferencia del uso típico de 2 dimensiones, como en las imágenes) y LSTM para determinar el tiempo de espera y el tiempo de tránsito por separado, que luego se combinan para la predicción final. Los autores utilizan un conjunto de datos tomados de la ciudad de Xiamen, China.

Nithishwer y cols. (2022) demuestran que los modelos de aprendizaje profundo presentan una mejora en la precisión de la predicción de tiempos de viaje en autobús al incorporar conocimientos específicos del dominio, como ser características espaciales y temporales. Además los autores presentan un método propio basado en CNN que supera en sus experimentos a los enfoques de promedio histórico, LR, ANN, LSTM y Conv-LSTM. Los datos fueron tomados de la ciudad de Chennai, India.

Concluyendo con esta clasificación, en el contexto de tipos de vehículos, tanto para vehículos particulares, taxis, como para el transporte público colectivo, se han explorado múltiples enfoques y tecnologías con distintos niveles de éxito. Algunos métodos basados en datos han demostrado ser relativamente precisos para predecir el tiempo de viaje de taxis y autos privados, pero presentaron limitaciones significativas cuando se aplican al transporte público colectivo debido a la naturaleza fija de las rutas de autobuses y las múltiples paradas en su recorrido. En este contexto, el tiempo de permanencia en las paradas afecta considerablemente el tiempo total de viaje, lo que complica la predicción precisa.

Si bien no existe un único método que ofrezca los mejores resultados, los experimentos actuales han sugerido que el aprendizaje profundo arroja una mejor precisión si se captan correctamente las correlaciones espaciales y temporales.

4.2. Clasificación según el entorno

Otra clasificación para la predicción del tiempo de viaje se relaciona con las características de la red vial: urbana o autopistas. Resolver la predicción de tiempos de viaje para estos dos entornos presenta algunas diferencias debido a condiciones como los límites de velocidad permitido, señalización, y una serie de diferencias que hace tratarlos a cada uno de una manera distinta. A continuación se trata cada uno de los entornos así como algunos de los trabajos recuperados en la revisión sistemática.

4.2.1. Autopistas

En entornos de autopistas el tráfico suele ser fluido y predecible, ya que mientras no exista congestión, la velocidad de los vehículos va a tender al límite permitido. Esto hace que la predicción del tiempo de viaje en autopistas sea más estable y menos afectada por factores imprevistos en comparación con los entornos urbanos.

A continuación se presentan algunos estudios que han abordado TTP en autopistas.

Xu y Liu (2021) abordan la predicción de tiempos de viaje en una carretera muy transitada cerca del Centro Deportivo Olímpico de Beijing, China, proponiendo un modelo innovador llamado *Multi-Component Network* (MC-Net). Este modelo integra componentes de atención espacio-temporal, eventos de tráfico y fusión de múltiples fuentes. Los autores utilizan redes de convolución en grafo para el análisis espacial y una arquitectura especializada para el análisis temporal. Los resultados muestran que MC-Net supera a otros métodos avanzados, destacando su precisión incluso ante eventos de tráfico no recurrentes gracias al componente de eventos de tráfico.

Motivados en aliviar la congestión del tráfico en la Carretera Provincial N.º 61 de Taiwán, M. Y. Chen y cols. (2022) desarrollan un Sistema de Transporte Inteligente Colaborativo (CITS, por su sigla en inglés) basado en 9 algoritmos diferentes para la predicción del tiempo de viaje actual y futuro. Lo novedoso de este trabajo es que presenta la tecnología CITS, donde los vehículos se mantienen informados en tiempo real y pueden así evitar la congestión del tráfico y más accidentes.

Qiu y Fan (2021) recopilaron datos de tiempo de viaje del Sistema Regional Integrado de Información de Transporte (RITIS, por su sigla en inglés) y predijeron los tiempos de viaje para horizontes cortos (de 15 a 60 minutos) en los corredores de autopistas aplicando cuatro algoritmos diferentes: DT, RFR, XGBoost y LSTM. Los autores utilizaron diversas características espaciales y temporales y compararon el rendimiento de precisión de predicción y confiabilidad. Sus resultados numéricos sugieren que RFR puede lograr un mejor rendimiento de predicción que cualquiera de los otros métodos no solo en precisión sino también en estabilidad. Además los autores señalan que RFR es menos propenso al sobreajuste y más resistente al ruido, debido a su proceso de selección de características aleatorias.

Bharathi y cols. (2023) proponen una metodología de predicción del tiempo de viaje para vehículos en autopistas de la ciudad de Dublín, República de Irlanda. El método propuesto está basado en LSTM, integrado con un algoritmo de descomposición modal (para mejorar la calidad de los datos de entrada), y un tipo de regresión llamada *Quantile Regression*. Los autores construyen un modelo de entrada múltiple y salida única teniendo en cuenta el flujo de tráfico y la velocidad como entradas para predecir el tiempo de viaje.

C. Y. Chen y cols. (2023) utilizan datos de la oficina de autopistas del Ministerio de Transporte de Taiwán para lograr mejorar significativamente la precisión predictiva del tiempo de viaje de 30 minutos por adelantado en comparación con varios métodos convencionales. Su método propio denominado *Bi-Directional⁴ Isometric-Gated Recurrent Unit* (BDIGRU) tiene la capacidad de aprender directamente características de alto nivel de grandes datos de tráfico y reconstruirlas mediante su propio mecanismo de atención. Como resultado positivo también logran determinar eficientemente la ruta óptima del vehículo.

⁴El término bi-direccional hace referencia a que la red procesa la secuencia de datos de tráfico en ambas direcciones, hacia adelante y hacia atrás. Esto permite que el modelo tenga en cuenta tanto la información pasada como la futura, mejorando la comprensión contextual.

4.2.2. Entorno urbano

Predecir el tiempo de viaje en un entorno urbano es inherentemente más complejo que en autopistas debido a factores adicionales, como los ciclos de señalización de múltiples intersecciones que están conectadas entre sí ([Abdollahi y cols., 2020](#)).

Además, según [M. Y. Chen y cols. \(2022\)](#) la congestión del tráfico tiende a ocurrir en áreas urbanas, por lo que eventos únicos como reparaciones de carreteras o mal tiempo tendrán un impacto significativo en el flujo de tráfico.

[Wang y cols. \(2023\)](#) citan que la principal dificultad de la predicción del tiempo de viaje urbano es la dinámica de los sistemas de transporte urbano. En su estudio los autores comentan que en cuanto a la dependencia temporal el tiempo de tránsito promedio siempre alcanza su punto máximo al mediodía y disminuye rápidamente durante los días de semana. Mientras que los fines de semana, los atascos de tráfico aparecen por la mañana y permanecen hasta el mediodía, y el grado de congestión es relativamente menor.

En cuanto a lo espacial, explican que hay múltiples rutas factibles desde el mismo punto de partida hasta un punto final, y la distribución de la velocidad promedio de cada segmento de carretera es significativamente diferente. Además, el tiempo de viaje de un segmento de carretera específico está influenciado no solo por su propio estado de tráfico, sino también por los segmentos conectados con él, por lo tanto es necesario predecir el estado del tráfico basado en las conexiones de la red vial.

[L. Zhang y cols. \(2021\)](#) compara modelos de aprendizaje automático y de aprendizaje profundo para el problema de predicción de tiempos de viaje en sistema urbano, analizando precisión, estabilidad y aplicabilidad. En cuanto a los métodos de aprendizaje automático explican que tienen dificultad para modelar con precisión el impacto de eventos de tráfico, como accidentes o construcciones, especialmente aquellos eventos repentinos que afectan los cambios en el tiempo de viaje. En cambios los métodos de aprendizaje profundo tienen la capacidad de generar una “memoria” para los patrones de tiempo de viaje en diferentes períodos durante el entrenamiento, y esto es notoriamente positivo. Sin embargo tras una extensa investigación, los autores concluyen que para la predicción del tiempo de viaje en carreteras urbanas, el aprendizaje profundo no ha superado completamente al aprendizaje superficial en todos los indicadores de evaluación, y que tiene muchos desafíos a resolver a futuro.

[Tang y cols. \(2019\)](#) realizan un estudio para la predicción de tiempos de viaje en entorno urbano de Nagoya, Japón, utilizando un modelo que se basa en los datos aportados por vehículos con sonda (FCD). A diferencia de otros métodos, este modelo para predecir utiliza ciclos de señales de tráfico (como pueden ser las señales de semáforos), en vez de ciclos de tiempo. Los datos que utilizaron fueron desagregados, tomados en bruto, de manera que reciben en tiempo real la información relevante (como puede ser ubicación, velocidad, aceleración, etc.) y no cada cierto período convencional de tiempo. De esta manera los autores logran tener un modelo exitoso que lo comparan contra el método k-NN y modelos ingenuos.

Thakkar y cols. (2021) realizan una comparación de algoritmos para resolver la predicción de tiempos de viaje en sistemas urbanos de India. A diferencia de otros estudios, utilizan sensores Wi-Fi para la recolección de los datos.

Ashwini y cols. (2022) presentan uno de los primeros estudios de predicción de tiempos de viaje urbano en Tumakuru, India, donde comparan métodos lineales y no lineales, obteniendo mejores resultados con los no lineales, y en particular con el método RFR.

Fan y cols. (2021) estudian la predicción de tiempos de viaje en sistema urbano para la ciudad de Beijing y Chengdu, China, con la particularidad que consideran múltiples formas de traslado, como ser a pie, en bicicleta, en vehículo, etc. También proponen un método propio al que denominan *Multimodal Convolutional Gated Recurrent Unit Network* (MC-GRU).

Concluyendo, en autopistas la fluidez del tráfico y la tendencia a la velocidad constante de los vehículos contribuyen a una mayor estabilidad en la predicción del tiempo de viaje. Esta estabilidad se debe a la menor incidencia de factores imprevistos y a la uniformidad de las condiciones de conducción. Por el contrario, en entornos urbanos, la complejidad aumenta significativamente debido a la presencia de intersecciones, semáforos y una mayor densidad de vehículos. Esta diversidad de variables hace que la predicción del tiempo de viaje sea más desafiante y menos precisa, ya que factores como la congestión del tráfico y eventos inesperados pueden influir de manera significativa en los tiempos de desplazamiento.

Además, la dinámica del tráfico urbano está sujeta a una variedad de patrones temporales y espaciales, como los picos de tráfico durante las horas pico y los cambios en la velocidad promedio en diferentes segmentos de carretera. Estos aspectos dificultan aún más la predicción precisa del tiempo de viaje en entornos urbanos, ya que se requiere considerar no solo la situación actual del tráfico, sino también las tendencias históricas y las interacciones entre los diferentes elementos de la red vial.

A lo largo de este Capítulo se ha mostrado que el estudio de la predicción del tiempo de viaje revela diferencias clave entre tipos de vehículos y tipos de entorno en el que se quiere predecir. Mientras que los métodos tradicionales son eficaces para vehículos individuales, el transporte público enfrenta más desafíos debido a la naturaleza fija de las rutas. Asimismo, en autopistas la fluidez del tráfico permite una predicción más estable, pero en entornos urbanos, la complejidad aumenta debido a la presencia de intersecciones, semáforos, etc. Aunque los modelos de aprendizaje profundo han avanzado, aún enfrentan dificultades para superar a los métodos tradicionales en la predicción del tiempo de viaje urbano, resaltando la necesidad de investigaciones futuras para mejorar la precisión en este contexto.

Capítulo 5

Enfoques para Resolver la Predicción del Tiempo de Viaje

En las secciones 2.1, 2.2 y 3, se han presentado los diversos elementos necesarios en el proceso de predicción. En la Sección 2.1, se analizaron los factores que inciden en la predicción. Seguidamente, en la Sección 2.2, se discutieron las fuentes de obtención de datos, así como las diferentes técnicas para su manipulación, incluyendo la depuración e interpolación. Por último, en el Capítulo 3 se presentó una posible clasificación donde se describieron varios métodos que pueden emplearse en la predicción.

En el Capítulo anterior, Capítulo 4, al igual que en este, se presentan dos temas que son transversales al proceso de TTP. El enfoque para resolver el TTP se refiere a la estrategia utilizada para abordar el problema.

Según los autores [Chughtai, Haq, Shafiq, y Muneeb \(2022\)](#), los métodos existentes de TTP pueden clasificarse en dos categorías principales: enfoques basados en la ruta y enfoques basados en datos.

Los enfoques basados en la ruta consideran la predicción como la suma de los tiempos de los segmentos y pueden o no tener en cuenta los tiempos de transición entre segmentos. Esta categoría se subdivide a su vez en:

1. Enfoque basado en Segmento (*segment-based*): solo considera el tiempo del segmento e ignora la correlación entre segmentos.
2. Enfoque basado en Subruta (*path-based*): Utiliza tanto el tiempo del segmento como los retrasos en las intersecciones.

Por otro lado, los enfoques basados en datos tienden a modelar el TTP de extremo a extremo, aprovechando las características espacio-temporales y aprendiendo correlaciones en los datos de tráfico. Esta categoría incluye:

1. Enfoque basado en la Trayectoria: Utiliza la red de carreteras y datos de trayectoria¹.
2. Enfoque basado en el Origen-Destino (OD): Considera solo los datos de ubicación de recogida y entrega y no incluye trayectorias intermedias.

Además, existe la posibilidad de emplear enfoques híbridos o combinados, donde se combinan diferentes modelos para mejorar la precisión de la predicción. Estos enfoques pueden ser:

1. Enfoque híbrido: combina modelos para crear uno nuevo, utilizado en toda la predicción.
2. Enfoque combinado: en la predicción de cada segmento se utilizan diferentes modelos y luego se realiza la suma.

La clasificación presentada no es un estándar y puede variar según los autores. Algunos autores presentan una clasificación un poco más simplificada y dividen los enfoques en basados en ruta y en OD (K. Zhang y cols., 2020), o basada en subruta, en segmento y en OD (Khaled y cols., 2022).

A continuación se presentan los enfoques más utilizados, según los artículos obtenidos de la revisión sistemática.

5.1. Enfoques basados en ruta

Según los autores Chughtai, Haq, Shafiq, y Muneeb (2022) y K. Zhang y cols. (2020) el enfoque basado en rutas considera la ruta completa, la divide en segmentos, y realiza la predicción para cada uno de ellos. Este enfoque se divide a su vez en dos subenfoques: el enfoque basado en segmentos y enfoque basado en subrutas. El primero de ellos consiste en realizar la predicción por cada uno de los segmentos y luego suma los tiempos para obtener el tiempo total del recorrido, ignorando la correlación entre segmentos lo cual acumula el error de predicción de cada segmento, lo que conlleva a predicciones inexactas (K. Zhang y cols., 2020; Khaled y cols., 2022). Mientras tanto, el enfoque basado en Subruta toma en consideración la relación entre los segmentos, es decir, el tiempo pasado en los cruces de camino (Khaled y cols., 2022).

Los métodos y modelos aplicados en el enfoque por segmento incluyen ARIMA y KF, utilizados en pronósticos a corto plazo para el tiempo de viaje de secciones de carretera, así como SVR, GBDT y LSTM. También se aplicó el método oculto de Markov espacio-temporal (STHM, por su sigla en inglés) para capturar las correlaciones entre diferentes series temporales de tráfico y luego predecir el tiempo de viaje (Khaled y cols., 2022).

Para el enfoque basado en subruta, los modelos son más complejos. Se utilizan datos del tráfico de diferentes fuentes y método k-shortest path para inferir el

¹Los autores no aclaran cuáles serían estos datos, pero del contexto se infiere que es información del vehículo a lo largo de la ruta, como por ejemplo posición, velocidad, dirección, etc.

camino más corto. Puede pasar que para algunos segmentos los datos sean escasos, por lo que se propone modelo CNN con LSTM (llamado DeepTTE) para el procesamiento de datos de trayectoria en bruto (Khaled y cols., 2022).

5.2. Enfoques basados en OD

Este enfoque ignora la información de trayectoria al calcular el tiempo de viaje. Este enfoque supera desafíos como la escasez de datos al evitar cálculos costosos para encontrar la ruta primero y luego calcular el tiempo de viaje (Khaled y cols., 2022).

Este enfoque ha ganado popularidad en los últimos años gracias a los avances en tecnologías de recolección de datos. Aprovecha las características espacio-temporales y aprende correlaciones en los datos de tráfico. Este enfoque requiere de modelos más complejos como CNN, redes neuronales profundas, LSTM, BiLSTM y GRU (Chughtai, ul Haq, y cols., 2022).

Los autores Elsir y cols. (2022) en su estado del arte relevan varios métodos utilizados en la predicción con enfoque OD, pero estos métodos no lograron una alta precisión debido a la complejidad del aprendizaje de correlaciones espacio-temporales, considerando la diferenciación de la topología de la red de carreteras y las condiciones temporales extremas. En su estudio, presentan una nueva técnica, llamada JSTC (*Joint Spatial-Temporal Correlation*), donde abordan principalmente el problema de la escasez de datos espaciales y también se centran en las correlaciones de múltiples factores espaciales, temporales y externos, que afectan significativamente el tiempo de viaje.

En conclusión, el problema de la predicción del tiempo de viaje puede abordarse desde diferentes enfoques. Se puede considerar enfoques basados en segmentos o en origen-destino. La predicción por segmentos requiere conocer todo el trayecto y se calcula como la suma de las predicciones de los segmentos, con la opción de considerar o no la relación entre ellos. Cuando no se considera dicha relación, los métodos a utilizar son más simples, pero acumulan el error de predicción de cada segmento, mientras que si se considera la relación entre los segmentos, se puede obtener una predicción más precisa, aunque los métodos sean más complejos. Por otro lado, en el enfoque origen-destino, el trayecto se desconoce y se utilizan métodos complejos como redes neuronales, que consideran características espacio-temporales, lo que puede generar que no se obtenga una alta precisión debido a la complejidad del aprendizaje de correlaciones espacio-temporales.

Capítulo 6

Conclusiones

En un mundo caracterizado por una creciente urbanización y avances continuos en las tecnologías de la información, que impulsa el desarrollo de ciudades inteligentes, el problema de predecir tiempos de viaje se vuelve cada vez más relevante en diferentes ámbitos. Las ciudades enfrentan desafíos complejos en movilidad urbana, siendo la congestión del tráfico uno de los principales. Esta congestión genera retrasos imprevistos, demoras en el tiempo de viaje y estrés en los conductores, además de tener impactos en la salud pública debido a la contaminación que genera y en la economía de gobiernos, empresas y usuarios particulares. A nivel de gobiernos genera altos costos ante la necesidad de agregar más infraestructura, a nivel de empresas repercute en aumentos de costos de la logística y a nivel de los usuarios finales por el alto costo en combustible.

En este contexto, la predicción de tiempos de viaje (TTP) emerge como una herramienta fundamental para abordar estos problemas. Contar con una predicción precisa del tiempo de viaje permite mejorar la planificación de los viajes, optimizar rutas y gestionar el tráfico y la congestión.

Por lo dicho anteriormente, el problema resulta de interés para múltiples actores. Interesa a empresas de omnibus y taxis, a conductores particulares, a empresas de logística y comercios en general, interesa a autoridades locales responsables de la planificación urbana, interesa en el ámbito de la salud y a empresas de desarrollo de aplicaciones y servicios de navegación.

El caso particular del TTP para los autobuses resulta de interés por múltiples motivos y para múltiples actores. El transporte público ofrece una solución al problema de la congestión, reduciendo significativamente la cantidad de vehículos en tránsito y, en consecuencia, disminuye la contaminación. Pero para que el transporte público resulte atractivo a los pasajeros, estos deben ofrecer un servicio confiable.

Afrontar el problema de TTP es una tarea compleja, que implica tener en cuenta una multiplicidad de elementos. Se debe considerar el tipo de vehículo, si se está en un contexto urbano o en autopista, si se desea una predicción a corto o largo plazo, y se deben tener en cuenta una gran diversidad de factores que pueden afectarlo; factores básicos como la ubicación y marca de tiempo, y otros

más complejos como eventos sociales y condiciones climáticas.

Tener en cuenta el tipo de vehículo es importante, ya que existen características implícitas a cada uno de ellos. Por ejemplo, en el caso de los taxis, se suelen identificar patrones de conducta diferentes al conductor particular. En el caso de los autobuses repercuten factores como la cantidad de personas que suben o bajan en cada parada, así como el tiempo que se permanece en estas.

El contexto en el que se da la predicción también es importante, ya que los patrones de comportamiento observados son bastante diferentes. Mientras que en autopistas el tránsito es más fluido y se manejan altas velocidades, en el contexto urbano deben tenerse en cuenta muchos factores adicionales como semáforos, cruces de peatones, velocidades mucho menores, eventos, etc., lo que puede hacer más complejo el proceso de predicción.

Para poder realizar la predicción existe una gran diversidad de modelos que se pueden aplicar y su elección depende de muchos aspectos. Depende de la cantidad y calidad de datos disponibles, de la cantidad de factores que se vayan a considerar, de la complejidad y el costo computacional, del tipo de predicción que se esté intentando realizar (ya sea a corto o largo plazo) y del nivel de precisión que se desee.

Si bien existe un amplio abanico de métodos que se pueden utilizar, los estudios realizados en los últimos años reflejan que hay una tendencia actual hacia la construcción de métodos orientados a datos, y de métodos híbridos que experimentan en la combinación de dos o más métodos, en un intento por mejorar la precisión en el proceso de predicción.

Referencias

- Abdollahi, M., Khaleghi, T., y Yang, K. (2020). An integrated feature learning approach using deep learning for travel time prediction. *Expert Systems with Applications*, 139(112982).
- Ahmed, I., Kumara, I., Reshadat, V., Kayes, A. S., van den Heuvel, W. J., y Tamburri, D. A. (2022). Travel time prediction and explanation with spatio-temporal features: A comparative study. *Electronics (Switzerland)*, 11(106).
- Alkilane, K., Alfateh, M. T. E., y Yanming, S. (2023). Travel time prediction based on route links' similarity. *Neural Computing and Applications*, 35, 3991-4007.
- Ashwini, B. P., Sumathi, R., y Sudhira, H. S. (2022). Bus travel time prediction: A comparative study of linear and non-linear machine learning models. En (Vol. 2161). IOP Publishing Ltd.
- Awad, M., y Khanna, R. (2015). *Efficient learning machines: Theories, concepts, and applications for engineers and system designers* (1st ed.). New York, NY: Apress Media, LLC.
- Bharathi, D., Sopeña, J. M. G., Clarke, S., y Ghosh, B. (2023). Travel time prediction utilizing hybrid deep learning models. *Transportation Research Record*, 2678, 56 - 65.
- Chang, T. H., Li, Y. R., Fu, C. H., Liu, Y. B., y Yang, S. M. (2019). Travel time prediction based on missing data compensation. En (Vol. 128, p. 328-336). Springer Science and Business Media Deutschland GmbH.
- Chen, C., Wang, H., Yuan, F., Jia, H., y Yao, B. (2020). Bus travel time prediction based on deep belief network with back-propagation. *Neural Computing and Applications*, 32, 10435-10449.
- Chen, C. H., Hwang, F. J., y Kung, H. Y. (2019). Travel time prediction system based on data clustering for waste collection vehicles. *IEICE Transactions on Information and Systems*, E102D, 1374-1383.
- Chen, C. Y., Sun, E. W., Chang, M. F., y Lin, Y. B. (2023). Enhancing travel time prediction with deep learning on chronological and retrospective time order information of big traffic data. *Annals of Operations Research*.
- Chen, M. Y., Chiang, H. S., y Yang, K. J. (2022). Constructing cooperative intelligent transport systems for travel time prediction with deep learning approaches. *IEEE Transactions on Intelligent Transportation Systems*, 23, 16590-16599.

- Chughtai, J.-U.-R., Haq, I. U., y Muneeb, M. (2022). An attention-based recurrent learning model for short-term travel time prediction. *PLoS ONE*, *17*(e0278064).
- Chughtai, J.-U.-R., Haq, I. U., Shafiq, O., y Muneeb, M. (2022). Travel time prediction using hybridized deep feature space and machine learning based heterogeneous ensemble. *IEEE Access*, *10*, 98127-98139.
- Chughtai, J.-U.-R., ul Haq, I., ul Islam, S., y Gani, A. (2022). A heterogeneous ensemble approach for travel time prediction using hybridized feature spaces and support vector regression. *Sensors*, *22*.
- Deb, B., Khan, S. R., Tanvir Hasan, K., Khan, A. H., y Alam, M. A. (2019). Travel time prediction using machine learning and weather impact on traffic conditions. En (p. 1-8).
- Elmi, S., y Tan, K. L. (2020). Travel time prediction in missing data areas: Feature-based transfer learning approach. En (p. 1088-1095). Institute of Electrical and Electronics Engineers Inc.
- Elsir, A. M. T., Khaled, A., Wang, P., y Shen, Y. (2022). Jstc: Travel time prediction with a joint spatial-temporal correlation mechanism. *Journal of Advanced Transportation*, *2022*.
- Fan, S., Li, J., Lv, Z., y Zhao, A. (2021). Multimodal traffic travel time prediction. En (p. 1-9). Institute of Electrical and Electronics Engineers Inc.
- Fang, H., Liu, Y., Chen, C. H., y Hwang, F. J. (2022). Travel time prediction method based on spatial-feature-based hierarchical clustering and deep multi-input gated recurrent unit. *ACM Transactions on Sensor Networks*, *19*(26).
- Fiosina, J. (2021). Explainable federated learning for taxi travel time prediction. En (Vol. 1, p. 670-677). Science and Technology Publications, Lda.
- Ghosal, S. S. (2019). Travel time prediction of taxis using tensor factorization. En (p. 314-317). Association for Computing Machinery.
- He, P., Jiang, G., Lam, S. K., y Tang, D. (2019). Travel-time prediction of bus journey with multiple bus trips. *IEEE Transactions on Intelligent Transportation Systems*, *20*, 4192-4205.
- Huang, H., Pouls, M., Meyer, A., y Pauly, M. (2020). Travel time prediction using tree-based ensembles. En (Vol. 12433, p. 412-427). Springer International Publishing.
- Huang, Y., Dai, H., y Tseng, V. S. (2022). Periodic attention-based stacked sequence to sequence framework for long-term travel time prediction. *Knowledge-Based Systems*, *258*(109976).
- Islek, I., y Oguducu, S. G. (2019). Use of lstm for short-term and long-term travel time prediction. En (Vol. 2482). CEUR-WS.
- Jakteerangkool, C., y Muangsin, V. (2020). Short-term travel time prediction from gps trace data using recurrent neural networks. En (p. 62-66). Institute of Electrical and Electronics Engineers Inc.
- Katayama, H., Yasuda, S., y Fuse, T. (2022). Comparative validation of spatial interpolation methods for traffic density for data-driven travel-time prediction. *International Journal of Intelligent Transportation Systems Research*, *20*, 830-837.

- Khaled, A., Elsir, A. M., y Shen, Y. (2022). Gsta: gated spatial-temporal attention approach for travel time prediction. *Neural Computing and Applications*, 34, 2307-2322.
- Kitchenham, B. (2004). *Procedures for performing systematic reviews* (Inf. Téc.). Keele University.
- Kumar, B. A., Jairam, R., Arkatkar, S. S., y Vanajakshi, L. (2019). Real time bus travel time prediction using k-nn classifier. *Transportation Letters*, 11, 362-372.
- Kumar, B. A., Mothukuri, S., y Vanajakshi, L. (2021). Numerical stability of conservation equation for bus travel time prediction using automatic vehicle location data. *International Journal of Intelligent Transportation Systems Research*, 19, 141-154.
- Kumar, B. A., Vanajakshi, L., y Subramanian, S. C. (2017). Bus travel time prediction using a time-space discretization approach. *Transportation Research Part C: Emerging Technologies*, 79, 308-332.
- Lee, G., Choo, S., Choi, S., y Lee, H. (2022). Does the inclusion of spatio-temporal features improve bus travel time predictions? a deep learning-based modelling approach. *Sustainability (Switzerland)*, 14(7431).
- Li, N., Wu, Y., Wang, Q., Ye, H., Wang, L., Jia, M., y Zhao, S. (2023). Underground mine truck travel time prediction based on stacking integrated learning. *Engineering Applications of Artificial Intelligence*, 120(105873).
- Li, X., Wang, H., Sun, P., y Zu, H. (2021). Spatiotemporal features-extracted travel time prediction leveraging deep-learning-enabled graph convolutional neural network model. *Sustainability (Switzerland)*, 13, 1-15.
- Li, Y., Zhang, M., Ding, Y., Zhou, Z., y Xu, L. (2022). Real-time travel time prediction based on evolving fuzzy participatory learning model. *Journal of Advanced Transportation*, 2022.
- Mendes-Moreira, J., y Baratchi, M. (2020). Reconciling predictions in the regression setting: An application to bus travel time prediction. En (Vol. 12080, p. 313-325). Springer.
- Moosavi, S. M. H., Aghaabbasi, M., Yuen, C. W., y Armaghani, D. J. (2023). Evaluation of applicability and accuracy of bus travel time prediction in high and low frequency bus routes using tree-based ml techniques. *Journal of Soft Computing in Civil Engineering*, 7, 74-97.
- Mori, U., Mendiburu, A., Álvarez, M., y Lozano, J. A. (2015). A review of travel time estimation and forecasting for advanced traveller information systems. *Transportmetrica A: Transport Science*, 11, 119-157.
- Nithishwer, M. A., Kumar, B. A., y Vanajakshi, L. (2022). Deep learning- just data or domain related knowledge adds value?: bus travel time prediction as a case study. *Transportation Letters*, 14, 863-873.
- Ou, Y. (2022). Ai for real-time bus travel time prediction in traffic congestion management. En (p. 63-84). Springer International Publishing.
- Petersen, N. C., Rodrigues, F., y Pereira, F. C. (2019). Multi-output bus travel time prediction with convolutional lstm neural network. *Expert Systems with Applications*, 120, 426-435.

- Putatunda, S., y Laha, A. K. (2023). Travel time prediction in real time for gps taxi data streams and its applications to travel safety. *Human-Centric Intelligent Systems*, 3, 381-401.
- Pérez-González, C. M., Mora-Vargas, J., Piña-Barcenas, J., y Cedillo-Campos, M. G. (2023). Method for travel time prediction in emerging markets based on anonymous truck gps data. *Annals of Operations Research*.
- Qiu, B., y Fan, W. (2021). Machine learning based short-term travel time prediction: Numerical results and comparative analyses. *Sustainability (Switzerland)*, 13(7454).
- Ran, X., Shan, Z., Fang, Y., y Lin, C. (2019). A convolution component-based method with attention mechanism for travel-time prediction. *Sensors (Switzerland)*, 19(2063).
- Ran, X., Shan, Z., Shi, Y., y Lin, C. (2019). Short-term travel time prediction: A spatiotemporal deep learning approach. *International Journal of Information Technology and Decision Making*, 18, 1087-1111.
- Schwinger, F., Frohnhofen, C., Wernz, J., Braun, S., y Jarke, M. (2021). Combining profile similarity and kalman filter for real-world applicable short-term bus travel time prediction. En (Vol. 2021-September, p. 3738-3745). Institute of Electrical and Electronics Engineers Inc.
- Shen, Y., Jin, C., Hua, J., y Huang, D. (2022). Ttpnet: A neural network for travel time prediction based on tensor decomposition and graph embedding. *IEEE Transactions on Knowledge and Data Engineering*, 34, 4514-4526.
- Sihag, G., Parida, M., y Kumar, P. (2022). Travel time prediction for traveler information system in heterogeneous disordered traffic conditions using gps trajectories. *Sustainability (Switzerland)*, 14(10070).
- Tang, R., Kanamori, R., y Yamamoto, T. (2019). Short-term urban link travel time prediction using dynamic time warping with disaggregate probe data. *IEEE Access*, 7, 98959-98970.
- Thakkar, S., Sharma, S., Advani, C., Arkatkar, S. S., y Bhaskar, A. (2021). Comparative analysis of travel time prediction algorithms for urban arterials using wi-fi sensor data. En (p. 697-702). Institute of Electrical and Electronics Engineers Inc.
- Wang, D., Zhu, J., Yin, Y., Ignatius, J., Wei, X., y Kumar, A. (2023). Dynamic travel time prediction with spatiotemporal features: using a gnn-based deep learning method. *Annals of Operations Research*.
- Wu, C. H., Ho, J. M., y Lee, D. T. (2004). Travel-time prediction with support vector regression. En (Vol. 5, p. 276-281).
- Wu, J. (2014). *Analysis of taxi drivers' driving behavior based on a driving simulator experiment*.
- Xu, M., y Liu, H. (2021). A flexible deep learning-aware framework for travel time prediction considering traffic event. *Engineering Applications of Artificial Intelligence*, 106(104491).
- Zhang, K., Lai, Y., Jiang, L., y Yang, F. (2020). Bus travel-time prediction based on deep spatio-temporal model. En (Vol. 12342, p. 369-383). Springer Science and Business Media Deutschland GmbH.

Zhang, L., Wang, Y., Yang, X., Zhang, C., Hao, Z., y Liu, Y. (2021). Travel time prediction for urban road based on machine learning: Review and prospect. En (p. 124-129). Institute of Electrical and Electronics Engineers Inc.

Anexo A

Anexo A. Revisión Sistemática

En esta Sección se presenta en mayor detalle el proceso llevado a cabo en la búsqueda y la justificación de las decisiones intermedias tomadas. También se presenta el *string* específico para cada buscador.

Luego del *string* inicial de búsqueda “travel time prediction” que arrojó un total de 6544 resultados, se realizó la misma búsqueda pero en la Sección título. Esto dio un resultado de 707 artículos. A partir de este resultado, se procede a probar con diferentes términos y analizar los resultados obtenidos. Aparte de los términos ya mencionados en el Capítulo 1.2 otro término con el que se analizó fue “data science” pero este no aportó cambios en los resultados de búsqueda, por lo que no se consideró parte del *string* final. Por cada uno de los términos se decidió realizar la búsqueda:

$string = TITLE (“travel\ time\ prediction”) AND TX (término\ específico)$

A modo de recordatorio, los términos utilizados son: “internet of vehicle” (IoV), “arrival time prediction” (ATP), “intelligent transportation system” (ITS), “deep learning” (DL), “machine learning” (ML) y “artificial intelligence” (AI).

La Tabla A.1 expone los resultados de estas búsquedas.

Colección	string inicial	IoV	ATP	ITS	DL	ML	AI
Springer Link	44	1	3	25	11	22	30
Scopus	487	5	98	372	108	140	186
IEEE Xplore X	120	1	11	23	22	52	10
Science Direct	56	1	12	31	12	28	10
Total	707	8	124	451	153	242	233

Tabla A.1: Resumen de cantidad de resultados.

Luego se decidió unir todos estos términos específicos en una única expresión

—con el operador lógico OR— para realizar una nueva búsqueda, pero esta vez en la Sección *abstract*, ya que ésta representa más fielmente el propósito de cada trabajo. La expresión lógica del string final es la siguiente:

$s2 = ABS ("internet\ of\ vehicle" OR "arrival\ time\ prediction" OR "intelligent\ transportation\ system" OR "deep\ learning" OR "machine\ learning" OR "artificial\ intelligence") AND TITLE ("travel\ time\ prediction")$

A continuación se presenta el *string* específico utilizado en cada buscador.

A.1. Buscador Springer Link

En este buscador no existe opción de buscar por Sección *abstract*, por lo que se procedió a buscar primero por título y luego en la siguiente pantalla, dentro de la barra de búsqueda se adicionó el término específico. Dado que este buscador está en transición a una nueva web, se deja en detalle todos los pasos:

1. Acceder a [Springer Link](#).
2. En la Sección *where the title contain* escribir "travel time prediction" y dar enter (el resto de los campos deben quedar vacíos).

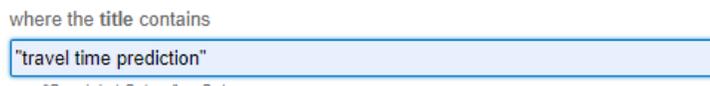


Figura A.1: Búsqueda por título.

3. En la nueva pantalla, en el buscador, escribir: "internet of vehicle" OR "arrival time prediction" OR "intelligent transportation system" OR "deep learning" OR "machine learning" OR "artificial intelligence". Esto va a buscar sobre la búsqueda anterior.

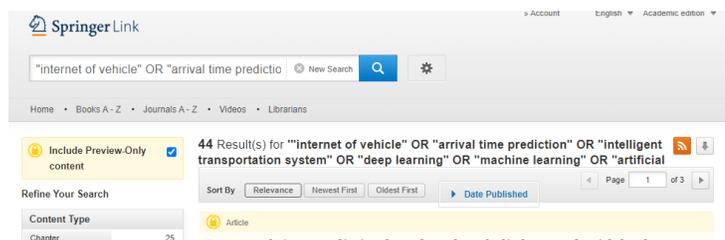


Figura A.2: String de términos.

Para acceder al enlace con el resultado de la búsqueda, seleccione [aquí](#). Recordar que la búsqueda se realizó el 17 de setiembre del 2023, por lo que deberá remover todos los resultados obtenidos luego de esa fecha y aplicar los criterios de exclusión detallados en el Capítulo 1.2.

A.2. Buscador Science Direct

En el buscador Science Direct no existe la opción de buscar únicamente por Sección *abstract*, pero sí contiene una Sección "title, abstract or author-specified keywords", por lo que se procedió a buscar allí.

1. Acceder a [Science Direct](#).
2. Seleccionar "Advanced Search".
3. Desplegar el campo "Show all fields".
4. En Sección title poner "travel time prediction".
5. En Sección title, abstract or author poner todos los términos anidados. y seleccionar search.
6. El resto de los campos deben quedar en blanco.

The image shows a search form with the following fields and content:

- Title, abstract or author-specified keywords:** "internet of vehicle" OR "arrival time prediction" OR "intelligent transportation system" OR "deep learning" OR "machine learning" OR "artificial intelligence"
- Title:** "travel time prediction"
- References:** (empty field)
- ISSN or ISBN:** (empty field)

At the bottom right, there are two buttons: "Cancel" and "Search" with a magnifying glass icon.

Figura A.3: Búsqueda en Science Direct.

Para acceder al enlace con el resultado de la búsqueda, seleccione [aquí](#). Recordar que la búsqueda se realizó el 17 de setiembre del 2023, por lo que deberá remover todos los resultados obtenidos luego de esa fecha y aplicar los criterios de exclusión detallados en la Sección 1.2.

A.3. Buscadores Scopus y IEEE Xplore

Estos dos buscadores poseen un campo *title* y un campo *abstract* por lo que la búsqueda a seguir es la detallada en la Sección [1.2](#).

Anexo B

Anexo B. Siglas

El presente anexo contiene una lista con las Siglas utilizadas en este documento. Se presenta la sigla, su definición, y en los casos en los que hace sentido se presenta la sigla en español.

Sigla	Definición en Inglés	Definición en Español
AI	Artificial Intelligence	Inteligencia Artificial
ANN	Artificial Neural Network	Red Neuronal Artificial
AR	Auto-Regressive	Autoregresivo
ARIMA	Auto-Regressive Integrated Moving Average	Autorregresivo integrado de media móvil
ARMA	Auto-Regressive Moving Average	Autorregresivo de media móvil
ATIS	Advanced Traveler Information Systems	Sistemas Avanzados de Información para Viajeros
ATP	Arrival Time Prediction	Predicción de hora de llegada
AVL	Automatic Vehicle Location	Localización Automática de Vehículos
BDIGRU	Bidirectional Isometric-Gated Recurrent Unit	-
CHAID	Chi-square Automatic Interaction Detection	Detección automática de interacciones a partir de Chi-Cuadrado
CITS	Cooperative Intelligent Transport Systems	Sistemas de Transporte Inteligente Cooperativo
CNN	Convolutional Neural Network	Red Neuronal Convolutiva
CORSIM	Corridor Simulation	Simulación de Corredores
DL	Deep Learning	Aprendizaje Profundo
DT	Decision Tree	Árbol de Decisión
FCD	Floating Car Data	Datos de Vehículos en Movimiento
GBDT	Gradient Boosting Decision Trees	-
GBR	Gradient Boosting Regression	-

GNN	Graph Neural Network	Red Neuronal de Grafos
GPS	Global Positioning System	Sistema de Posicionamiento Global
GRU	Gated Recurrent Unit	-
IoT	Internet of Things	Internet de las Cosas
IoV	Internet of Vehicle	-
ITS	Intelligent Transportation System	Sistema de Transporte Inteligente
JSTC	Joint Spatial-Temporal Correlation	-
k-NN	k-Nearest Neighbors	k-Vecinos Más Cercanos
KF	Kalman Filter	Filtro de Kalman
LASSO	Least Absolute Shrinkage and Selection Operator	-
LR	Linear Regression	Regresión Lineal
LSTM	Long Short-Term Memory	-
MA	Moving Average	Media Móvil
MC-GRU	Multimodal Convolved Gated Recurrent Unit Network	-
ML	Machine Learning	Aprendizaje Automático
MLP	Multilayer Perceptron	Perceptrón Multicapa
OD	Origin-Destination	Origen-Destino
QR	Quantile Regression	Regresión Cuantil
R4R	Reconciliation for Regression	-
RF	Random Forest	Bosque Aleatorio
RFR	Random Forest Regression	-
RITIS	Regional Integrated Transportation Information System	-
RNN	Recurrent Neural Network	Red Neuronal Recurrente
RR	Ridge Regression	Regresión Ridge
RS	-	Revisión Sistemática
RT	Regression Trees	Árboles de regresión
SARIMA	Seasonal Auto-Regressive Integrated Moving Average	-
STHM	Spatio-Temporal Hidden Markov	-
SVR	Support Vector Regression	Regresión de Vectores de Soporte
TTP	Travel Time Prediction	Predicción de Tiempo de Viaje