

MODELACIÓN Y ANÁLISIS ESPACIOTEMPORAL DE LA DEMANDA DE VIAJES EN RIDESOURCING EN SANTIAGO DE CHILE

Bastían Domínguez, Universidad de Chile, bastian.dominguez@ug.uchile.cl

Alejandro Tirachini, University of Twente y Universidad de Chile, alejandro.tirachini@utwente.nl

Marcela Munizaga, Universidad de Chile y Sistemas Complejos de Ingeniería, mamuniza@ing.uchile.cl

C. Ángelo Guevara, Universidad de Chile y Sistemas Complejos de Ingeniería, rguevar@ing.uchile.cl

RESUMEN

El estudio de viajes en ridesourcing con información liberada por las compañías se ha limitado a ciudades estadounidenses y chinas, siendo éste el primer estudio de este tipo en Latinoamérica. Se examinan datos de viajes en Didi, sociodemografía, entorno construido y oferta de transporte en Santiago. Se construyen modelos zonales de generación de viajes por día y período, usando regresión lineal 2SLS. Los resultados muestran que la demanda es mayor en zonas con mayor ingreso, densidad poblacional, diversidad de actividades e infraestructura de transporte público; menor posesión de automóvil y frecuencia de buses. También se identifican puntos relevantes como centros comerciales, terminales de buses y el aeropuerto. Además, al corregir por endogeneidad, se observa una relación inversa entre demanda y tiempo de espera. Finalmente, la identificación del patrón de viajes permite inferir propósitos de viaje, destacando los propósitos de ocio y trabajo.

Palabras Clave: ridesourcing, modelos de demanda, sociodemografía, entorno construido

ABSTRACT

The study of ridesourcing trips with data released by ridesourcing companies has been limited to American and Chinese cities, so this is the first study of its kind in Latin America. Data from Didi trips, sociodemographics, built environment and transportation supply in Santiago are examined. Zonal travel generation models are constructed by day and period, using 2SLS linear regression. The results show that demand is higher in areas with higher income, population density, activity diversity and public transport infrastructure; lower car ownership and bus frequency. Relevant points such as shopping centers, bus terminals and the airport are also identified. Furthermore, when correcting for endogeneity, an inverse relationship between demand and waiting time is observed. Finally, the identification of the travel pattern allows inferring travel purposes, highlighting leisure and work purposes.

Keywords: ridesourcing, demand models, sociodemographics, built environment

1 INTRODUCCIÓN

El concepto *ridesourcing* se usa para referirse a servicios de transporte dados por empresas como Uber, Didi o Cabify, en los que un usuario solicita un viaje mediante una aplicación, donde es puesto en contacto con un conductor que acepta realizar ese viaje. Estos servicios ofrecen viajes ‘puerta a puerta’ a un costo menor que el de los taxis (Días et al, 2017), con las comodidades que ofrece un automóvil sin los costos de tener uno. Además son de fácil acceso, ya que sólo se requiere entrar a la aplicación para solicitar el viaje y realizar el pago.

A causa de estas ventajas, el *ridesourcing* ha tenido gran éxito desde su aparición, logrando un crecimiento enorme (Ghaffar et al, 2020; Dey et al, 2021) y generando diversos impactos en varias ciudades del mundo. Dentro de los positivos está la aparición de un nuevo modo de transporte que da la cobertura y flexibilidad que no puede dar el transporte público (Rayle et al, 2016; Ghaffar et al, 2020). Por otro lado, puede impactar negativamente la ciudad aumentando el flujo vehicular, debido a sustituciones desde modos más eficientes, la adición de kilómetros en vacío, y un aumento de viajes por demanda inducida (Tirachini, 2020). Debido a la multiplicidad de estos impactos, es crucial entender cómo el uso de estas plataformas afecta los patrones de actividades, el uso de otros modos de transporte, la posesión de automóvil, la equidad social y la congestión, entre otros (Alemi et al, 2018b; Tirachini, 2020). Así, se espera que las autoridades puedan elaborar políticas que incentiven los impactos positivos y reduzcan los negativos (Ghaffar et al., 2020).

Varios autores coinciden en que un obstáculo para estudiar estos temas ha sido la ausencia de datos de viajes (Lavieri et al, 2018; Marquet, 2020). Para superar este problema, algunos han usado encuestas como método de adquisición de datos, permitiendo obtener información de usuarios. Sin embargo, en los últimos años se han liberado datos de viajes en *ridesourcing* en ciudades de EE.UU. y China. Ambas fuentes de datos tienen sus virtudes y debilidades, por lo que pueden complementarse para verificar resultados (Ghaffar et al, 2020).

El objetivo de este trabajo es contribuir a la literatura existente sobre este fenómeno, en particular sobre el comportamiento de viajes en este modo. Para ello, se usan datos de viajes realizados en Santiago mediante la plataforma Didi, para elaborar modelos de generación de viajes a nivel agregado, incluyendo como variables explicativas atributos de modo, sociodemografía, entorno construido y oferta de transporte.

Este estudio aporta varias novedades en relación a trabajos previos. Hasta donde sabemos, este es el primer trabajo realizado con datos de viajes en *ridesourcing* en una ciudad latinoamericana, ampliando el análisis a contextos distintos a los estudiados a la fecha. También se estiman modelos por día y período para capturar la influencia de los factores analizados, según el momento del día. Por último, se tiene la inclusión de atributos de modo, en particular la velocidad y el tiempo de espera.

La estructura de este trabajo es la siguiente: luego de esta introducción, en la Sección 2 se presenta una revisión de trabajos anteriores que abordan este tema. En la Sección 3 se describen los datos y la metodología para la confección de los modelos. En la Sección 4 se presentan los resultados obtenidos. Finalmente, en la Sección 5 se mencionan las principales conclusiones de este estudio.

2 ESTADO DEL ARTE

Varios autores afirman que el conocimiento del *ridesourcing* aún es limitado (Tirachini y del Río, 2019; Marquet, 2020). No obstante, la liberación de datos de viajes ha permitido avanzar en varias direcciones. Según Alemi et al (2018a) y Bekka et al (2020), la literatura se divide en dos grandes grupos. El primer grupo - dentro del cual está este trabajo - estudia los factores que inciden en la elección y uso de este modo, perfil de usuarios, propósitos y patrones espaciotemporales. El segundo grupo discute sus potenciales impactos en la elección de modo, posesión de automóvil, patrones de actividades y congestión, entre otros. A ellos se suman dos grupos más: el tercero estudia la oferta de *ridesourcing* y mecanismos de tarificación óptima (e.g, Li et al, 2021; Gómez-Lobo et al, 2022); y el cuarto estudia el comportamiento de conductores y el efecto del *ridesourcing* en el mercado laboral (e.g, Hall y Krueger, 2018; Fielbaum y Tirachini, 2021).

En esta sección se revisa la literatura relacionada con el uso del ridesourcing, haciendo énfasis en el primer grupo. Se extiende y actualiza la revisión realizada por Tirachini (2020), que cubre estudios hasta 2019.

2.1 Estudios basados en encuestas

Uno de los mayores obstáculos en el estudio del ridesourcing ha sido la falta de datos de viajes. Las compañías de ridesourcing han sido reacias a compartir información de usuarios y viajes por motivos de privacidad (Lavieri y Bhat, 2019) y sus propios intereses. Por ello, gran parte de la literatura se basa en encuestas, que ofrecen información detallada a nivel de usuario, pero con menor cobertura y posibles sesgos. Las encuestas se enfocan en la caracterización de usuarios y sus propósitos de viaje, el comportamiento de viajes y los impactos del ridesourcing (Li et al, 2019; Tirachini, 2020).

En la literatura basada en encuestas hay estudios de carácter exploratorio, cuyos resultados se apoyan en estadística descriptiva (e.g, Rayle et al, 2016; Clewlow y Mishra, 2017; Young y Farber, 2019); un segundo grupo se dedica a la estimación de modelos econométricos de uso de ridesourcing a nivel individual (e.g, Dias et al, 2017; Alemi et al, 2018a; Aguilera-García et al, 2022). A pesar de las diferencias metodológicas, sus conclusiones son similares en cuanto a caracterización de usuarios y comportamiento de viajes.

Según Rayle et al (2016), los usuarios de ridesourcing en San Francisco son jóvenes y con mejor educación y poder adquisitivo que el promedio de la población. Clewlow y Mishra (2017) hallaron que solo el 4% de las personas mayores de 65 años ha usado estos servicios, mientras que el 36% de la población entre 18 y 29 años lo ha hecho. Además, los usuarios de mayor ingreso y nivel educativo los usan con más frecuencia que el resto de la población. Dias et al (2017) concluyen que los usuarios de ridesourcing son usualmente jóvenes con ingreso y nivel educativo altos, y viven en áreas densamente pobladas. Por otro lado, Alemi et al (2018a) analizan los factores que influyen en el uso de Uber y Lyft, encontrando que los millennials con alto nivel educativo y poder adquisitivo son más propensos a usar estos servicios.

La mayoría de las investigaciones se han hecho en ciudades estadounidenses, aunque también se han hallado estudios en Chile, Canadá y España, entre otros. Si bien el contexto difiere en cada país, los resultados no varían demasiado. Young y Farber (2019) obtienen que los usuarios de ridesourcing en Toronto suelen ser adultos jóvenes, de ingreso alto y sin automóvil. En Santiago, Tirachini y del Río (2019) obtienen que los usuarios más jóvenes y con mayor ingreso usan este modo más frecuentemente. Por último, Aguilera-García et al (2022) sugieren que en España hay mayor tendencia a usar ridesourcing por parte de mujeres, adultos jóvenes y personas de ingreso alto cuando el viaje no es urgente; mientras que los mayores de 49 años usan ridesourcing cuando el viaje es más urgente.

En cuanto al comportamiento de viajes, varios autores coinciden en que los viajes en ridesourcing suelen ser de carácter ocasional y que los principales propósitos son el ocio y el retorno al hogar (Rayle et al., 2016; Tirachini y del Río, 2019; Aguilera-García et al., 2022). Los viajes de retorno se pueden asociar a actividades laborales y sociales. De hecho, una de las principales razones por la que los usuarios prefieren ridesourcing en vez de conducir su propio vehículo es el consumo de alcohol (Clewlow y Mishra, 2017; Tirachini y del Río, 2019). Este comportamiento se refleja en el patrón de viajes, ya que en varias ciudades se ha visto que la mayor demanda se da en períodos nocturnos y fines de semana (Tirachini y del Río, 2019; Bi y Ye, 2021).

2.2 Estudios basados en datos espaciotemporales de viajes

A la fecha, la liberación de datos de viajes por parte de las compañías de ridesourcing se ha dado sólo en algunas ciudades de Estados Unidos y China. Estos datos poseen gran cobertura espacial, ya que contienen información de todos los viajes hechos en la ciudad durante cierto período, permitiendo desarrollar modelos de demanda a nivel agregado. Sin embargo, la información de usuarios se encuentra anonimizada.

Si bien en la literatura hay trabajos en que se analiza la demanda de viajes en taxi a partir de datos de viajes (e.g, Chen et al, 2021), el primer trabajo de este tipo aplicado a ridesourcing del cual se tiene registro es el de Correa et al (2017). Los autores usan datos de viajes en Uber y taxis en Nueva York entre 2014 y 2015

para estimar la generación de viajes mediante modelos de regresión lineal y correlación espacial. Los resultados indican que el uso de ridesourcing se asocia a áreas de mayor ingreso, nivel educativo, menor posesión de automóvil, como también zonas con más puestos de empleo, oferta de vías y paraderos de buses.

Gerte et al. (2018) usa la misma base de datos para elaborar un modelo lineal con efectos aleatorios mediante mínimos cuadrados generalizados, aunque considera variables distintas a las usadas en Correa et al. (2017), dando mayor relevancia a factores temporales como el clima. Los resultados muestran que la demanda es mayor en zonas con mayor población joven, mayor presencia masculina y nivel educativo, además de zonas con mayor uso de suelo residencial y de retail. En cuanto a las variables temporales, se tiene un mayor uso de ridesourcing cuando las condiciones climáticas no son favorables, como en invierno o en días de lluvia.

La liberación de datos de viajes del servicio RideAustin en Austin, Texas entre 2016 y 2017 permitió nuevas investigaciones. Lavieri et al. (2018) analizan la generación de viajes usando modelos de conteo con retardo espacial para días laborales y fin de semana, además de la distribución de viajes usando modelos de partición fraccionaria. Los resultados indican que la demanda es mayor en áreas con población joven y menor posesión de automóvil, así como en zonas con alta densidad de población, empleo y presencia de parques. Un hallazgo interesante es que en días laborales la demanda crece con el ingreso, mientras que en fin de semana sucede lo opuesto. Se tiene un patrón similar en la composición de género: en día laboral, la demanda se relaciona directamente con la proporción de varones, mientras que en fin de semana ocurre lo contrario.

Yu y Peng (2019) usan los mismos datos, aunque considerando otro enfoque de modelación. Los autores usan una regresión Poisson geográficamente ponderada para capturar una eventual correlación espacial de las variables, además añaden variables de entorno construido, tales como densidad de población y empleo, uso de suelo e infraestructura. A nivel de sociodemografía, los resultados indican que existe mayor demanda de viajes en zonas con población más joven y de mayor nivel educativo, mientras que para el ingreso se observan dos efectos: en días laborales hay una relación inversa, mientras que en fin de semana la relación es directa, contrario a lo obtenido en Lavieri et al. (2018). En cuanto a entorno construido, la demanda crece en zonas con mayor densidad de población, diversidad de actividades y acceso al transporte público.

Brown (2019) utiliza una regresión binomial negativa para estimar la generación de viajes en Los Ángeles, California, usando datos de viajes en Lyft realizados entre septiembre y noviembre de 2016. Sus resultados indican que los barrios con más población joven, mayor densidad de población y de empleo, mayor cantidad de paraderos y con menor disponibilidad de estacionamientos se asocian a una mayor demanda de viajes.

Ghaffar et al. (2020) analizan los viajes realizados en Chicago entre noviembre de 2018 y marzo de 2019, usando una regresión binomial negativa con efectos aleatorios, añadiendo variables de clima y delincuencia. Los resultados respaldan las conclusiones de estudios anteriores, mostrando que la demanda crece en áreas con mayor ingreso, hogares sin automóvil, densidad de población y empleo, diversidad de actividades, presencia de restaurantes, escasez de estacionamientos y casos de homicidio. También se observa una mayor demanda los fines de semana y en días con temperaturas más bajas y menos precipitación.

Con los mismos datos, Marquet (2020) estima un modelo de distribución mediante una regresión Poisson truncada, usando variables de sociodemografía y entorno construido, con énfasis en las cualidades de los barrios en donde inicia y acaba el viaje, además de la ‘caminabilidad’ del viaje. Sus resultados revelan una relación directa entre la demanda en un par origen-destino con el ingreso, la caminabilidad y las densidades de población y empleo. A diferencia de otros trabajos, se tiene una relación inversa entre la demanda y la ausencia de automóvil en el hogar.

Sabouri et al (2020) usan datos de viajes en Uber en 24 ciudades de EE.UU. entre enero y marzo de 2017 para construir un modelo lineal jerárquico, incluyendo variables de sociodemografía y entorno construido, además del tiempo de viaje. Los resultados asocian una mayor demanda a sectores con mayor población y empleo, ingreso promedio, mix de uso de suelo y densidad de paraderos; así como sectores con menor edad promedio y posesión de automóvil. También se tiene una relación inversa entre demanda y tiempo de viaje.

Los estudios anteriores usan bases de datos de ciudades estadounidenses. Hasta la fecha, sólo se conoce un estudio realizado con datos de viajes en otro país, realizado por Wang y Noland (2021). Los autores usan datos de viajes en Didi realizados en Chengdu, China durante noviembre de 2016 para estimar un modelo de regresión lineal OLS y una regresión geográficamente ponderada. No usan variables sociodemográficas, a excepción del valor de las viviendas como proxy de la condición socioeconómica de cada unidad espacial. Se obtiene que la demanda se relaciona directamente con la densidad poblacional, el valor de las viviendas, el número de restaurantes y la proximidad a estaciones de metro. Un resultado llamativo es que no se observa correlación entre la demanda y el mix de uso de suelo.

Tabla 1: Cuadro resumen de trabajos basados en análisis de datos de viajes

Autor(es)	Ciudad	Periodo	Etapas	Modelo	Variable explicada
Correa et al (2017)	Nueva York	Abr 2014 - Sep 2014 Ene 2015 - Jun 2015	Generación	Modelo de retardo espacial Modelo de error espacial	Viajes totales por zona
Gerte et al (2018)	Nueva York	Abr 2014 - Sep 2014 Ene 2015 - Jun 2015	Generación	Regresión Lineal GLS con efectos aleatorios	Viajes semanales
Lavieri et al (2018)	Austin	Ago 2016 - Ene 2017	Generación Distribución	Modelo conteo con retardo esp. Modelo de partición frac.	Viajes diarios por zona (lab-fds)
Yu y Peng (2019)	Austin	Sep 2016 - Mar 2017	-	Regresión Poisson geográficamente ponderada	Viajes diarios por zona
Brown (2019)	Los Ángeles	Sep 2016 - Nov 2016	Generación	Regresión binomial negativa	Viajes por zona
Marquet (2020)	Chicago	Nov 2018 - Jun 2019	Distribución	Regresión Poisson truncada	Viajes diarios por zona
Ghaffar et al (2020)	Chicago	Nov 2018 - Mar 2019	Generación y Atracción	Regresión binomial negativa con efectos aleatorios	Viajes diarios por zona
Sabouri et al (2020)	US	Ene 2017 - Mar 2017	Distribución	Modelo lineal jerárquico	Viajes mensuales entre zonas (log)
Dey et al (2021)	Nueva York	Ene 2015 - Dic 2018	Generación	Regresión binomial negativa	Viajes totales por zona
Wang y Noland (2021)	Chengdu	Nov 2016	Generación	Regresión lineal OLS Modelo con retardo esp.	Viajes mensuales por zona

3 METODOLOGÍA

3.1 Datos

3.1.1 Recolección de datos

La base de datos principal contiene datos de viajes en ridesourcing facilitados por Didi Chuxing, mediante un acuerdo de colaboración con la Universidad de Chile. Se incluye información de las solicitudes de viaje realizadas en la Región Metropolitana entre el 13 y 26 de enero de 2020. En total, hay 1.369.643 solicitudes con 67 atributos. Los datos relevantes incluyen identificadores de solicitud, usuario y conductor, así como la dirección del origen y la distancia origen-destino. También se registran fechas y horas importantes del viaje, como la solicitud del servicio, la llegada del vehículo, la cancelación (si aplica) y el término del viaje. Es importante señalar que la información está anonimizada y no se dispone de datos del destino de los viajes.

Se construyen variables de tiempo de espera, tiempo de viaje y velocidad media a partir de los atributos originales. El tiempo de espera se calcula como la duración entre la solicitud del servicio y la llegada del vehículo, el tiempo de viaje se calcula desde la llegada del vehículo hasta el término del viaje, y la velocidad media se obtiene dividiendo la distancia recorrida por el tiempo real de viaje. Estas nuevas variables brindan una caracterización más precisa de los viajes, permiten establecer criterios para la limpieza de datos y se pueden incorporar como atributos en el modelo.

Los datos de viajes se complementan con otras fuentes que incluyen elementos de sociodemografía, entorno construido y oferta de transporte. Estos datos se imputan a los viajes mediante su origen. Si bien es coherente para los datos de entorno construido y oferta de transporte, en el caso de la sociodemografía lo sería sólo para los viajes basados en el hogar, lo cual ocurre principalmente en el período punta mañana de la ciudad.

La sociodemografía considera aspectos relacionados con las personas y hogares, tales como el ingreso, posesión de automóvil o nivel educativo. Estas variables se obtienen de las bases de datos de la EOD 2012 (SECTRA, 2013). Si bien el objetivo principal de esta encuesta es caracterizar el comportamiento de viajes de la población, entrega información socioeconómica valiosa que puede ser georreferenciada. A partir de estas bases de datos se obtienen los atributos de ingreso y de posesión de automóvil.

El entorno construido es un concepto multidimensional que captura atributos del entorno donde las personas viven y realizan sus actividades, tales como el uso de suelo, edificios y calles. La inclusión de estas variables es relevante, ya que su impacto sobre los viajes en ridesourcing permite modelar de mejor forma la demanda y planear estrategias de planificación eficientes (Yu y Peng, 2019). En este estudio, se recolectan datos de densidad poblacional, uso de suelo y sitios de interés. La información de población y unidades de análisis se obtienen del Censo 2017 (INE, 2018). Por otro lado, los datos de uso de suelo se obtienen de la base de datos de predios de Santiago para el año 2014 entregados por el SII (CEDEUS, 2016). Por último, se incorpora la ubicación de puntos de interés como centros comerciales, terminales de buses y aeropuertos.

Las variables de oferta de transporte se añaden para estudiar su relación con el uso de ridesourcing. Los modos considerados en este trabajo son bus, metro y bicicleta. En el caso de los buses se tienen dos variables: paraderos y frecuencia, obtenidos del programa de operación de 2019 (DTPM, 2019). También se incorpora la ubicación de las estaciones de metro existentes a la fecha. Por último, la factibilidad de viajar en bicicleta se captura mediante la oferta de ciclovías en la ciudad, obtenida del Visor de Ciclovías (MTT, 2021).

3.1.2 Procesamiento de datos

En primer lugar, se considera como área de estudio las 32 comunas de la provincia de Santiago, junto con las comunas de San Bernardo y Puente Alto, debido a la calidad y disponibilidad de los datos. Dicha área se zonifica en 339 distritos censales (en adelante DC). Luego, se realiza una geocodificación de los datos de viajes para poder asignar cada observación a uno de los DC según el origen del viaje.

Después, se realiza una limpieza de datos considerando una serie de filtros, con el fin de conservar los viajes cuyas cualidades sean razonables para la modelación. De este modo, la base de datos de viajes se reduce a 944.479 observaciones (69% de la base de datos original). El detalle del proceso se muestra en la Figura 1.

Finalmente, se construyen variables a nivel de DC, que son incluidas en los modelos de demanda. De los datos de viajes se calcula el total de viajes, distancia promedio, tiempo de viaje promedio, tiempo de espera promedio y velocidad media espacial. A partir de los datos de sociodemografía se calculan composiciones por ingreso y posesión de automóvil. En cuanto a las variables de entorno construido, se obtiene el número de sitios de interés y el mix de uso de suelo. Como variables de oferta de transporte se calcula la frecuencia promedio de buses y la densidad de paraderos. Del mismo modo, se calcula la densidad de ciclovías.




Figura 1: Limpieza de base de datos de viajes en ridesourcing

3.1.3 Análisis Descriptivo

La Figura 2 muestra los histogramas de distancia, tiempo de viaje real, tiempo de espera y velocidad media. Se observa que todos tienen una distribución log-normal como resultado de la acumulación de observaciones en valores bajos, pero con valores máximos muy altos. De hecho, en todos los casos se ve que la moda es cercana al 25% y el promedio es superior al 50% de las observaciones.




Figura 2: Histogramas de atributos de ridesourcing

Además, en la Figura 3 se reporta un histograma con la frecuencia de uso, donde se observa una forma exponencial, lo que permite afirmar que el uso de ridesourcing es preferentemente ocasional. De hecho, de los 303.471 usuarios que utilizaron el servicio durante las dos semanas de análisis, el 42% utiliza el servicio sólo una vez, mientras que el 62% no lo utiliza más de dos veces.




Figura 3: Histograma de frecuencia de uso

La Figura 4 muestra el perfil de viajes en las dos semanas de estudio, revelando un patrón regular. Durante los días laborales, se nota claramente una punta mañana entre las 07:00 y las 10:00 hrs., y una punta tarde que crece durante de la semana. El día viernes tiene un comportamiento levemente distinto, con una punta tarde que comienza antes y se hace pronunciada. En el sábado desaparece la punta mañana y la punta tarde alcanza su máximo semanal. Por último, el domingo presentan una reducción considerable en la demanda y tiene un perfil más plano.




Figura 4: Perfil de Viajes

Para realizar un análisis más detallado y capturar patrones de viajes específicos, se definen 4 tipos de día: lunes a jueves, viernes, sábado y domingo. Además, se descompone cada día en 5 períodos: nocturno 2 (N2: 00:00-06:59), punta mañana (PM: 07:00-09:59), fuera de punta (FP: 09:00-17:29), punta tarde (PT: 17:30-20:59) y nocturno 1 (N1: 21:00-23:59). En PM, durante los días laborales se realiza un 15% del total de viajes diario, mientras que durante el fin de semana este porcentaje se reduce a menos del 10 %. En FP se realiza cerca del 40% en días laborales y un 34% en fin de semana. Luego, en PT se tiene cerca del 20% durante toda la semana. Por otra parte, en N1 pasa de alrededor de un 15% entre domingo y jueves a poco menos del 20% en los días restantes. Por último, en N2 hay un aumento significativo, pasando de un 6 y 7% en días laborales a un 14 y 20% en fin de semana.

Los porcentajes están influenciados por el tamaño de cada período, por lo que no son suficientes para dar una idea precisa de la demanda durante cada uno. En la Figura 5 se reporta el número de viajes promedio por hora en cada día-período. Se observa que en los días laborales, la demanda en N2 es cercana a los 1.000 viajes/hr, pero en el fin de semana aumenta a más del doble. Por otro lado, en PM ocurre lo opuesto: en los días laborales existe una demanda del orden de los 4.000 viajes/hr y en el fin de semana se reduce a casi la mitad. En FP y PT la demanda es estable durante toda la semana, aunque en este último hay un aumento entre el 10 y 15% en viernes y sábado. Por último, en N1 hay un aumento más notorio en dichos días.




Figura 5: Viajes promedio por hora según día-período

La Figura 6 muestra la distribución espacial de los viajes. El mapa (a) describe a la distribución de los viajes totales por DC, donde se observa que los viajes se concentran en los sectores centro y oriente de Santiago, comunas con gran población y algunos sectores específicos. Sin embargo, esta distribución está influenciada por el tamaño de los DC. Para aislar este efecto, los mapas (b) y (c) muestran la distribución de variables de viaje normalizadas por superficie y número de hogares, respectivamente. Al normalizar por superficie, la concentración es más clara en el centro, ya que las zonas en ese sector son más pequeñas. Por otro lado, al normalizar por hogares, cobran relevancia algunas zonas fuera del centro, ya que tienen pocos hogares.




Figura 6: Distribución espacial de (a) Viajes Totales, (b) Viajes por km² y (c) Viajes por cada 1.000 hogares

3.2 Modelación

Para modelar la demanda de viajes, se estiman modelos de regresión lineal múltiple por día y período. Se consideran dos variables explicadas: viajes diarios por km² y viajes diarios por cada 1.000 hogares. Ambas permiten eliminar el efecto del tamaño de los DC, aunque tienen algunas diferencias: la primera representa una densidad de viajes generados sin importar las actividades que se realicen en cada DC, mientras que la segunda se asimila de mejor manera a modelos basados en el hogar, habituales en la literatura de transporte.

Debido a que el total de viajes es una variable de conteo, no es correcto usar directamente regresión lineal, ya que puede generar valores ajustados negativos. Para garantizar que la estimación sea consistente con la naturaleza no negativa de las variables explicadas, se define una relación exponencial con las variables explicativas, dando origen a un modelo log-lineal. Un problema de esto es la aparición de ceros en la variable explicada. Para corregirlo hay varios métodos, siendo los más comunes el uso de $\log(Y + \Delta)$ (e.g., Dey et al, 2021) y eliminar los ceros. Según Bellego et al (2022), sumar un término arbitrario dentro del logaritmo es complejo porque genera endogeneidad y reduce los errores estándar artificialmente, mientras que eliminar observaciones cero induce sesgo de selección. No obstante, como sólo 43 de las 6.780 combinaciones DC-período no tienen viajes y 42 de ellas son en períodos nocturnos, se opta por eliminar dichas observaciones.

Se sospecha la existencia de endogeneidad en los atributos de viaje debido a un problema de determinación simultánea. En el caso del tiempo de espera, se debe a que depende del número de conductores circulando en el sector, que a su vez depende de la demanda. También es razonable pensar que existe endogeneidad en la velocidad: por un lado, una menor velocidad desincentiva el uso de ridesourcing, pero por otro lado esta reducción de velocidad podría estar asociada a una mayor congestión, donde la demanda suele ser mayor.

Para corregir por endogeneidad, se incluyen variables instrumentales mediante regresión lineal por mínimos cuadrados en 2 etapas. Los instrumentos considerados son la variable en el período anterior y el promedio comunal de la variable, exceptuando el DC en cuestión, incorporando así una componente temporal y una espacial. El uso de la primera se sustenta en que cada zona posee la misma infraestructura sin importar el período, por lo que se espera que haya correlación en la variable de una zona en distintos períodos. El uso de la segunda se debe a que las zonas vecinas suelen tener infraestructura similar, lo que explicaría una correlación en zonas aledañas, pero no necesariamente responden a los mismos shocks de demanda.

Además de la endogeneidad, se detecta la presencia de heterocedasticidad en los modelos. El tratamiento de este problema se describe en detalle en Domínguez (2023).

Luego de estimar los modelos, también se evalúa su capacidad predictiva. Para ello, se usan los datos de la primera semana para estimar los modelos y luego se evalúan con los datos de la segunda semana. La capacidad predictiva se mide a través del error porcentual medio absoluto (MAPE), dado por la ecuación 1:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{T_i}{t_i} - 1 \right| \quad (1)$$

donde T_i es el valor de la variable explicada estimada mediante los modelos, t_i es el valor de la variable explicada observada en los datos y N es la cantidad de observaciones.

4 RESULTADOS

4.1 Resultados de los Modelos

A continuación, se presentan los resultados de los modelos estimados. Cada tabla contiene los resultados de 4 modelos, correspondientes a cada tipo de día para los períodos PM y PT, mientras que el resto se presenta en detalle en Domínguez (2023). Las tablas contienen los coeficientes y el nivel de significancia de las variables, usando la notación de RStudio¹. Además, se reporta la bondad de ajuste, los resultados de los test de hipótesis de endogeneidad, del test de correlación espacial de Moran y la capacidad de predicción.

Como ambas variables dependientes presentan resultados similares, se muestran solamente los resultados de la densidad de viajes. Los resultados para los viajes normalizados por hogar se muestran en detalle en Domínguez (2023). Además, los resultados consideran como variable endógena el tiempo de espera, ya que estos modelos presentan el comportamiento más plausible, según lo presentado en Domínguez (2023).

¹ Códigos de significancia de acuerdo a $\Pr(> |t|)$: 0 (***) 0.001 (**) 0.01 (*) 0.05 (.) 0.10 () 1

Tabla 2: Resultados modelación viajes por km², período PM

Categoría	Variable	LUN-JUE		VIE		SAB		DOM	
-	Intercepto	-2,205	**	-3,689	***	-2,981	**	-4,163	**
Atributos de Ridesourcing	Tiempo de espera [min]	-0,317	***	-0,253	***	-0,593	***	-0,540	***
	Velocidad media espacial [km/h]	-0,065	***	-0,031	***	-0,008		-0,002	
Sociodemografía	% hogares ingreso medio	0,578	**	0,548	*	0,666	*	1,112	***
	% hogares ingreso alto	1,819	***	2,113	***	0,068		0,073	
	% hogares con 1 auto	-0,179		-0,180	.	0,155		-0,033	
	% hogares con 2+ autos	-0,368		-0,513	***	-1,089	**	-0,875	*
Entorno Construido	(log) Densidad poblacional [hab/km ²]	0,832	***	0,866	**	0,929	***	0,932	***
	Mix de uso de suelo	0,457	*	0,719	**	0,484		0,649	.
	Mall tipo 1	-0,141	.	-0,228		-0,066		-0,028	
	Mall tipo 2	0,207		0,023		-0,170		0,403	
	Mall tipo 3	0,213		0,206	.	0,225		-0,038	
	Dummy Aeropuerto	1,591	*	2,782	.	3,542	***	2,320	*
	Dummy Terminal	0,591	*	0,821	**	0,763	*	0,526	
Oferta de Transporte	Dummy CBD	0,017		0,099		-0,112		-0,373	*
	Densidad Paraderos [par/km ²]	0,005	.	0,005	.	-0,004		0,001	
	Frecuencia Buses [bus/hr]	-0,061	*	-0,057	.	-0,098	.	-0,044	
	Dummy Metro	0,103	.	0,165	**	0,092		0,031	
Ajuste del Modelo	Oferta Ciclovías [km/km ²]	-0,008		-0,003		0,004		0,030	.
	R ²	0,812		0,751		0,697		0,552	
Test de Hipótesis Variables Instrumentales	Instrumentos Débiles	101,562	***	41,645	***	21,968	***	14,460	***
	Wu-Hausman	13,965	***	13,642	***	24,680	***	25,760	***
	Sargan	1,913		1,144		3,064		7,660	***
Correlación Esp.	Moran	0,328	***	0,282	***	0,107	***	0,002	***
Predicción	MAPE	14,6%		23,8%		35,6%		171,6%	
Núm. Obs.	N	339		339		338		339	

Tabla 3: Resultados modelación viajes por km², período PT

Categoría	Variable	LUN-JUE		VIE		SAB		DOM	
-	Intercepto	0,254		-0,880		-1,010		-1,393	.
Atributos de Ridesourcing	Tiempo de espera [min]	-0,375	***	-0,311	***	-0,433	***	-0,492	***
	Velocidad media espacial [km/h]	-0,052	***	-0,031	**	-0,017	*	-0,004	
Sociodemografía	% hogares ingreso medio	0,406	*	0,503	*	-0,009		0,488	*
	% hogares ingreso alto	1,638	***	1,720	***	0,531		0,436	
	% hogares con 1 auto	-0,283		-0,107		0,173		-0,288	
	% hogares con 2+ autos	-0,391		-0,663	*	-0,617	*	-0,497	.
Entorno Construido	(log) Densidad poblacional [hab/km ²]	0,506	***	0,565	***	0,682	***	0,656	***
	Mix de uso de suelo	1,098	***	1,921	***	0,787	***	0,566	**
	Mall tipo 1	0,096		0,086		0,116		0,086	
	Mall tipo 2	0,553	***	0,461	**	0,523	**	0,639	***
	Mall tipo 3	0,789	***	0,653	***	0,732	***	0,951	***
	Dummy Aeropuerto	2,407	***	1,635	*	2,277	***	2,350	***
	Dummy Terminal	1,196	***	1,066	***	0,795	***	1,097	***
Oferta de Transporte	Dummy CBD	0,427	***	0,408	***	0,237	**	0,012	
	Densidad Paraderos [par/km ²]	0,007	**	0,011	***	0,003		0,003	
	Frecuencia Buses [bus/hr]	-0,034		-0,040		-0,070	.	0,003	
	Dummy Metro	0,275	***	0,289	***	0,168	**	0,076	
Ajuste del Modelo	Oferta Ciclovías [km/km ²]	0,037	***	0,019	.	0,025	*	0,022	
	R ²	0,807		0,775		0,796		0,796	
Test de Hipótesis Variables Instrumentales	Instrumentos Débiles	209,936	***	92,538	***	85,300	***	59,450	***
	Wu-Hausman	57,893	***	43,321	***	28,220	***	32,060	***
	Sargan	1,458		0,034		0,290		6,710	**
Correlación Esp.	Moran	0,182	***	0,106	***	0,188	***	0,146	***
Predicción	MAPE	15,2%		63,9%		17,5%		26,5%	
Núm. Obs.	N	339		339		339		339	

4.2 Interpretación de los modelos

En general, se obtiene un mejor ajuste y capacidad de predicción en los modelos de día laboral PM, FP y PT, lo que indica que las variables consideradas explican en gran parte la demanda de viajes en ridesourcing.

Sin embargo, para el fin de semana y especialmente en N1 y N2 no se logra el mismo rendimiento, por lo que se sospecha que existen otras variables no incluidas en los modelos que explican la demanda en estos períodos. Los resultados son similares para ambas variables dependientes, a excepción del coeficiente de densidad poblacional que presenta signos opuestos. Además, los modelos de densidad de viajes presentan mejor bondad de ajuste, posiblemente debido a que algunas variables explicativas están naturalmente normalizadas por unidad de superficie, como la densidad poblacional, de paraderos y de ciclovías.

4.2.1 Atributos de Ridesourcing

En todos los modelos se observa una relación inversa entre demanda y tiempo de espera, es decir, las zonas con menor tiempo de espera generan mayor demanda. Esta relación es razonable debido a que un menor tiempo de espera es un incentivo para preferir ridesourcing, e incluso a preferir Didi por sobre otras plataformas. Además, los test de hipótesis indican que efectivamente existe endogeneidad en el tiempo de espera y que las variables instrumentales propuestas son apropiadas.

Concordando con la literatura (Lavieri et al, 2018; Marquet, 2020, Ghaffar et al, 2020, Dey et al, 2021), los modelos sugieren que hay mayor demanda en zonas con mayor presencia de hogares de ingreso alto. Sin embargo, se debe señalar que esta relación sólo se da en días laborales. Aun así esto es razonable, pues los usuarios de ingreso alto tienen más facilidad para pagar reiteradamente las tarifas del ridesourcing, a menudo más altas que las de transporte público. Además, los resultados revelan que en fin de semana el uso de ridesourcing es más transversal socioeconómicamente, similar a lo obtenido en Lavieri et al (2018).

El caso de la velocidad es más complejo. En los períodos laborales-diurnos existe una relación inversa con la demanda, sugiriendo que es mayor en zonas con baja velocidad. Es poco probable que los usuarios elijan deliberadamente este modo cuando es más lento, más bien lo que debe estar ocurriendo es que los DC con baja velocidad presentan congestión debido a la mayor demanda. De hecho, en la estimación de modelos se estudió una posible endogeneidad en esta variable, bajo la premisa de que el flujo vehicular de Didi genera congestión, pero los resultados indican que la endogeneidad es más débil que la del tiempo de espera, e incluso en algunos períodos no se detecta. Esto pudo ocurrir porque la congestión no depende solo del ridesourcing, sino que es resultado de los flujos de distintos modos que circulan en el sector.

4.2.2 Sociodemografía

La relación entre posesión de automóvil y uso de ridesourcing ha sido una de las más complejas de analizar en la literatura, con resultados mixtos. En nuestro caso, se obtuvo que la mayoría de los coeficientes no son estadísticamente significativos (resultado concordante con el estudio previo de Tirachini y del Río, 2019 en Chile, basado en encuestas). Los parámetros son usualmente negativos, y son significativos solo para viernes y sábado, para la tasa de hogares con 2 o más vehículos, indicando que para altas tasas de motorización si hay una correlación negativa con el uso de ridesourcing, al menos en fines de semana. Es natural pensar que una persona sin automóvil tiene mayores incentivos a usar ridesourcing que una persona que sí lo tiene, ya que estos últimos suelen dejar de lado su vehículo sólo en casos puntuales, como la falta de estacionamientos o consumo de alcohol. De hecho, según una encuesta de uso de Uber en Chile analizada en Tirachini y Gómez-Lobo (2020), más del 20% de los encuestados usan Uber debido a la falta de disponibilidad o al alto costo de los estacionamientos, y más del 40% lo usa para no conducir luego del consumo de alcohol.

Por otro lado, los resultados no revelan una relación significativa de la demanda con la composición etaria y de género. Esto se podría explicar por la distribución espacial homogénea de ambas variables, a diferencia del ingreso y posesión de automóvil que son segregados. Además, se debe recordar que a cada viaje se ha imputado los atributos del origen, lo cual es más apropiado para viajes generados desde el hogar. Para obtener una relación más clara de la demanda con la edad y género, sería más conveniente realizar encuestas a usuarios. Por último, en el caso del nivel educativo, tampoco se obtuvo una relación estadísticamente significativa con la demanda, a pesar de su distribución espacial segregada. La razón por la cual puede estar ocurriendo esto es que el nivel educativo está correlacionado con el ingreso.

4.2.3 Entorno Construido

Se observan efectos opuestos en la relación de la demanda con la densidad poblacional, dependiendo de la variable explicada. Para la densidad de viajes, se observa una relación positiva entre demanda y densidad poblacional en todos los días y períodos, siendo consistente con los resultados hallados en la literatura (Ghaffar et al, 2020; Lavieri et al, 2018; Yu y Peng, 2019, entre otros). Este resultado sugiere que hay mayor densidad de viajes en las zonas con mayor densidad poblacional, las cuales se ubican en su mayoría en el centro. Por otro lado, al modelar los viajes normalizados por hogares, se tiene una relación inversa, es decir, cuando la densidad poblacional crece, los viajes por hogar se reducen. Esto puede explicarse por las diferencias en la distribución espacial de la densidad poblacional y del número de hogares: los sectores centro y oriente tienen una alta densidad de población y número de hogares debido al gran número de edificios residenciales en esos sectores; por el contrario, la periferia tiene un gran número de hogares, pero baja densidad poblacional debido al mayor tamaño de las zonas y que las viviendas son en su mayoría casas.

En segundo lugar, los modelos indican una relación positiva entre demanda y mix de uso de suelo en todos los pares día-período, es decir, hay mayor demanda en las zonas con mayor diversidad de actividades. Una posible explicación es que los viajes se realizan desde los centros de actividades hacia el hogar, es decir, viajes de retorno. Más aún, se observa que en PM la relación es más débil, lo cual podría explicarse debido a que en este período debiera haber más viajes al trabajo, los cuales se hacen desde el hogar.

Además, los modelos reafirman la importancia de los centros comerciales en la demanda de viajes, pues se observa una relación directa en los períodos en que están en funcionamiento, especialmente con centros comerciales de gran tamaño. Del mismo modo, se verifica la influencia del aeropuerto y los terminales de buses. En el caso de la variable dummy aeropuerto, se obtuvo una relación positiva y significativa en todas las combinaciones día-período. Por su parte, la variable dummy terminal presenta una relación más débil, pero aun así constituyen una fuente importante de generación de viajes. Por último, la variable dummy CBD es más relevante en FP y PT, donde se asocia positivamente con la demanda. Esto indica que durante tales períodos se generan más viajes desde centros de actividades, posiblemente de retorno al hogar.

4.2.4 Oferta de Transporte

Los modelos revelan una relación directa de la demanda con la infraestructura de transporte público, al igual que en varios trabajos previos (Correa et al, 2017; Brown, 2019; Ghaffar et al, 2020; Sabouri et al, 2020; Dey et al, 2021). Esto indica que existe mayor demanda en sectores con más paraderos y estaciones de metro, principalmente en FP, PT y N1. Una hipótesis es que el ridesourcing se usa para el viaje de última milla, por lo que este modo se complementaría con el transporte público. No obstante, esto no coincide con los resultados de Tirachini y del Río (2019), quienes obtuvieron que el 96% de los usuarios de ridesourcing no combina con otros modos en Santiago. Una segunda hipótesis es que este modo se usa para volver al hogar desde centros de actividades, que son las zonas con mayor infraestructura de transporte público. Una tercera opción es que los usuarios suelen ser multimodales (Tirachini, 2020): si bien la evidencia indica que en Santiago no suelen combinar modos en un mismo viaje, siguen siendo usuarios habituales de otros modos y en particular de transporte público, usando ridesourcing para viajes específicos. Este comportamiento sólo puede darse en zonas servidas por transporte público. En resumen, esta relación entre el uso de ridesourcing y la infraestructura de transporte público posiblemente es el resultado de la combinación de estos factores.

En cuanto a la frecuencia de buses, se tiene una relación inversa con la demanda en PM, N1 y N2, es decir, hay mayor uso de ridesourcing en sectores y períodos donde la frecuencia de buses es menor. Esto concuerda con lo obtenido por Lavieri et al (2018), quienes también usan esta variable. Este resultado sugiere que parte del uso del ridesourcing se debe a la falta de cobertura de transporte público: si bien en PM la frecuencia de buses es mayor, las personas suelen tener poco tiempo y una baja frecuencia es preocupante; por otro lado, en N1 y N2 la frecuencia se reduce considerablemente - en algunos casos incluso no circulan buses - lo que obliga a los usuarios a buscar otras opciones. Esto no se observa en FP y PT, donde la disponibilidad de buses es mayor y además las personas cuentan con mayor holgura de tiempo, a diferencia de PM.

Por último, se tiene una relación positiva de la oferta de ciclovías con el uso de ridesourcing, lo que sugiere que estos modos podrían complementarse. No obstante, debido al bajo uso combinado del ridesourcing con otros modos, este resultado seguramente se debe a que la oferta de ciclovías está correlacionada con sectores definidos como CBD, donde existe una mayor demanda.

4.3 Patrón de Viajes

El análisis del patrón de viajes revela similitudes con algunos resultados de Tirachini y del Río (2019). En primer lugar, se verifica que los días de mayor demanda son viernes y sábado: en dicho estudio el 28% de los encuestados responde que el viernes es el día que más usan ridesourcing y un 36% responde que el sábado; mientras que en este trabajo se obtuvo que el 16% de los viajes se realizaron los viernes y un 16% los sábados. En segundo lugar, también coinciden los horarios de mayor demanda: en el estudio anterior el 36% de los usuarios responde que el horario en que más se usa ridesourcing es entre 20:00 y 23:59, mientras que un 23% responde entre 17:00 y 20:00; en este trabajo se obtuvo que un 22% y un 17% de los viajes se realizan respectivamente en esos horarios. Por último, existen semejanzas en la frecuencia de uso: un 58% de los usuarios encuestados usó Uber entre 2 y 4 veces en un mes, un 19% entre 5 y 8 veces, y un 9% más de 8 veces. Si se amplifican por 2 las frecuencias de la Figura 3, se tiene de forma aproximada que en un mes un 62% usó Didi entre 2 y 4 veces, un 12% entre 5 y 8 veces y el 26% restante más de 8 veces.

Además de la regularidad semanal, se observa una regularidad dentro de la semana, lo que permite inferir algunos propósitos de viaje. La punta mañana en día laboral se puede atribuir a viajes con propósito trabajo. En Tirachini y del Río (2019), los viajes con este propósito conforman el 17% de los viajes realizados por los encuestados, mientras que en este estudio los viajes en PM en día laboral corresponden al 11% del total. Esta hipótesis se reafirma al comparar con el patrón de viajes observado durante la mañana de sábado y domingo, donde no se ve este peak. Más aún, dada la recurrencia de los viajes con propósito trabajo, es razonable pensar que son realizados por usuarios de ingreso alto, lo que es consistente con los resultados.

5 CONCLUSIONES

En este trabajo se estudiaron los factores que participan en el uso de ridesourcing en Santiago. En particular, se usaron datos de viajes realizados en Didi, junto con datos de sociodemografía, entorno construido y oferta de transporte para desarrollar modelos de generación de viajes por día-período a nivel de DC. Entre las contribuciones de este estudio está la extensión del alcance de esta línea de investigación al contexto latinoamericano, la corrección de los modelos para el cumplimiento de las condiciones de Gauss-Markov y la detección de diferentes grados de influencia de los factores según el día y período de los viajes.

Aunque el contexto varía entre ciudades, los resultados revelan similitudes con trabajos previos. La demanda crece con el ingreso, densidad poblacional, diversidad de actividades, número de sitios de interés, paraderos y estaciones de metro; mientras que decrece con la posesión de automóvil, frecuencia de buses y tiempo de espera. Al respecto, hay 3 resultados interesantes: (1) hay mayor participación de hogares de ingreso alto en días laborales, mientras que en fin de semana su uso es transversal; (2) la demanda se relaciona inversamente con el tiempo de espera, que si bien es un resultado esperable, no se había medido anteriormente; (3) la demanda se relaciona inversamente con la velocidad en períodos de mayor actividad, revelando la existencia de congestión en zonas de alta demanda.

De forma complementaria, se examinó el patrón espaciotemporal de viajes en este modo, logrando inferir algunos de los propósitos de viaje para los cuales se usan estos servicios. Se observaron peaks en la mañana y en la tarde, además de un aumento considerable de la demanda en la noche de viernes y sábado, por lo que se concluye que los principales propósitos de viaje son ocio y trabajo. Los resultados de este análisis son consistentes con estudios previos realizados en Santiago.

Los resultados y métodos de este trabajo pueden ser relevantes para diversos actores. Por una parte, son relevantes para los operadores de Didi (y otras compañías de ridesourcing), ya que el conocimiento del

comportamiento de viajes en este modo les permite planificar estrategias para servir esta demanda de forma eficiente, por ejemplo mediante la asignación de conductores o la estimación de flota óptima (Lavieri et al., 2018). Por otro lado, los resultados también pueden resultar de gran importancia para los entes reguladores y autoridades, ya que el conocer los factores que influyen en el uso de ridesourcing y los impactos que provoca permite enfocar correctamente los esfuerzos para promover o desincentivar su uso.

REFERENCIAS

- Aguilera-García, A., Gomez, J., Velázquez, G., y Vassallo, J. M. (2022). Ridesourcing vs. traditional taxi services: Understanding users' choices and preferences in Spain. **Transportation Research Part A: Policy and Practice**, 155:161–178.
- Alemi, F., Circella, G., Handy, S., y Mokhtarian, P. (2018a). What influences travelers to use Uber? Exploring the factors affecting the adoption of on-demand ride services in California. **Travel Behaviour and Society**, 13:88–104.
- Alemi, F., Circella, G., Mokhtarian, P., y Handy, S. (2018b). Exploring the latent constructs behind the use of ridehailing in California. **Journal of Choice Modelling**, 29:47–62.
- Bekka, A., Louvet, N., y Adoue, F. (2020). Impact of a ridesourcing service on car ownership and resulting effects on vehicle kilometers travelled in the Paris Region. **Case Studies on Transport Policy**, 8(3):1010–1018.
- Bellego, C., Benatia, D., y Pape, L. (2022). Dealing with logs and zeros in regression models.
- Bi, H. y Ye, Z. (2021). Exploring ridesourcing trip patterns by fusing multi-source data: A big data approach. **Sustainable Cities and Society**, 64:102499.
- Brown, A. (2019). Redefining car access. **Journal of the American Planning Association**, 85(2):83–95.
- Centro de Desarrollo Urbano Sustentable (2016). Uso de suelo - Chile. http://datos.cedeus.cl/layers/geonode:cl_uso_suelo_geo. Fecha de acceso 18-07-2021.
- Chen, C., Feng, T., Shao, M., y Yao, B. (2021). Understanding the determinants of spatiotemporal mobility patterns based on multi-source heterogeneous data. **Transportation Research Procedia**, 52:477–484.
- Clewlow, R. R. y Mishra, G. S. (2017). Disruptive transportation: The adoption, utilization, and impacts of ride-hailing in the United States. **Transport Policy**, 45:168–178.
- Correa, D., Xie, K., y Ozbay, K. (2017). Exploring the taxi and uber demand in New York city: An empirical analysis and spatial modeling.
- Dey, B. K., Tirtha, S. D., Eluru, N., y Konduri, K. C. (2021). Transformation of ridehailing in New York City: A quantitative assessment. **Transportation Research Part C: Emerging Technologies**, 129:103235.
- Dias, F., Lavieri, P., Garikapati, V., Astroza, S., Pendyala, R., y Bhat, C. (2017). A behavioral choice model of the use of car-sharing and ride-sourcing services. **Transportation**, 44.
- Directorio de Transporte Público Metropolitano (2019). Planes Operacionales Históricas. <https://www.dtpm.cl/index.php/noticias/plan-operacional-historico>. Fecha de acceso 14-06-2021.
- Domínguez, B. (2023). Modelación y análisis espaciotemporal de la demanda de viajes en ridesourcing en Santiago de Chile.
- Fielbaum, A. y Tirachini, A. (2021). The sharing economy and the job market: the case of ride-hailing drivers in Chile. **Transportation**, 48.
- Gerte, R., Konduri, K., y Eluru, N. (2018). Is there a limit to adoption of dynamic ridesharing systems? evidence from analysis of Uber demand data from New York city. **Transportation Research Record: Journal of the Transportation Research Board**, 2672:036119811878846.
- Ghaffar, A., Mitra, S., y Hyland, M. (2020). Modeling determinants of ridesourcing usage: A census tract-level analysis of Chicago. **Transportation Research Part C: Emerging Technologies**, 119:102769.

- Gómez-Lobo, A., Tirachini, A., y Gutierrez, I. (2022). Optimal prices for ridesourcing in the presence of taxi, public transport and car competition. **Transportation Research Part C: Emerging Technologies**, 137:103591.
- Hall, J. V. y Krueger, A. B. (2018). An Analysis of the labor market for Uber's driver-partners in the United States. **ILR Review**, 71(3):705–732.
- INE (2018). Censo 2017 Distrito Censal: Población, viviendas por área y densidad. https://geoine-inechile.opendata.arcgis.com/datasets/c6e62e8bd9f04a6a9df46f46f1f22fd_0/about. Fecha de acceso 31-05-2021.
- Jin, S. T., Kong, H., Wu, R., y Sui, D. Z. (2018). Ridesourcing, the sharing economy, and the future of cities. **Cities**, 76:96–104.
- Lavieri, P. S. y Bhat, C. R. (2019). Investigating objective and subjective factors influencing the adoption, frequency, and characteristics of ride-hailing trips. **Transportation Research Part C: Emerging Technologies**, 105:100–125.
- Lavieri, P., F. Dias, F., Ruíz-Juri, N., Kuhr, J., y Bhat, C. (2018). A model of ridesourcing demand generation and distribution. **Transportation Research Record Journal of the Transportation Research Board**, 2672.
- Li, S., Yang, H., Poolla, K., y Varaiya, P. (2021). Spatial pricing in ride-sourcing markets under a congestion charge. **Transportation Research Part B: Methodological**, 152:18–45.
- Li, W., Pu, Z., Li, Y., y (Jeff) Ban, X. (2019). Characterization of ridesplitting based on observed data: A case study of Chengdu, China. **Transportation Research Part C: Emerging Technologies**, 100:330–353.
- Marquet, O. (2020). Spatial distribution of ride-hailing trip demand and its association with walkability and neighborhood characteristics. **Cities**, 106:102926.
- Ministerio de Transporte y Telecomunicaciones (2021). Visor de Ciclovías. <https://ciclovias.visorterritorial.cl/>. Fecha de acceso 14-06-2021.
- Rayle, L., Dai, D., Chan, N., Cervero, R., y Shaheen, S. (2016). Just a better taxi? A survey-based ride-hailing drivers in Chile. **Transportation**, 48.
- Sabouri, S., Park, K., Smith, A., Tian, G., y Ewing, R. (2020). Exploring the influence of built environment on Uber demand. **Transportation Research Part D: Transport and Environment**, 81:102296.
- SECTRA (2013). Encuestas de Movilidad. http://www.sectra.gob.cl/encuestas_movilidad/encuestas_movilidad.htm. Fecha de acceso 20-06-2021.
- Tirachini, A. (2020). Ride-hailing, travel behaviour and sustainable mobility: an international review. **Transportation**, 47.
- Tirachini, A. y del Río, M. (2019). Ride-hailing in Santiago de Chile: Users' characterization and effects on travel behaviour. **Transport Policy**, 82:46–57.
- Tirachini, A. y Gómez-Lobo, A. (2020). Does ride-hailing increase or decrease vehicle kilometers traveled (VKT)? A simulation approach for Santiago de Chile. **International Journal of Sustainable Transportation**, 14:1–18.
- Wang, H. y Yang, H. (2019). Ridesourcing systems: A framework and review. **Transportation Research Part B: Methodological**, 129:122–155.
- Wang, S. y Noland, R. B. (2021). Variation in ride-hailing trips in Chengdu, China. **Transportation Research Part D: Transport and Environment**, 90:102596.
- Wu, X. y MacKenzie, D. (2021). Assessing the VMT effect of ridesourcing services in the US. **Transportation Research Part D: Transport and Environment**, 94:102816.
- Young, M. y Farber, S. (2019). The who, why, and when of Uber and other ride-hailing trips: An examination of a large sample household travel survey. **Transportation Research Part A: Policy and Practice**, 119:383–392.
- Yu, H. y Peng, Z.-R. (2019). Exploring the spatial variation of ridesourcing demand and its relationship to built environment and socioeconomic factors with the geographically weighted poisson regression. **Journal of Transport Geography**, 75:147–163.