



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA CIVIL

**ANÁLISIS DE LOS EFECTOS DE LA PANDEMIA POR COVID-19 SOBRE LA
MOVILIDAD DE LOS USUARIOS DEL TRANSPORTE PÚBLICO DE SANTIAGO, A
PARTIR DE DATOS DE TARJETAS INTELIGENTES**

**TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE LA
INGENIERÍA, MENCIÓN TRANSPORTE**

JAVIERA PAZ GODACHEVICH CONTRERAS

PROFESORES GUÍA:
CRISTIAN GUEVARA CUE
MARCELA MUNIZAGA MUÑOZ

MIEMBROS DE LA COMISIÓN:
ALEJANDRO TIRACHINI HERNÁNDEZ
SEBASTIÁN ASTROZA TAGLE

SANTIAGO DE CHILE
2022

RESUMEN DE LA TESIS PARA OPTAR AL GRADO DE MAGÍSTER
EN CIENCIAS DE LA INGENIERA, MENCIÓN TRANSPORTE
POR: JAVIERA PAZ GODACHEVICH CONTRERAS
FECHA: 2022
PROF. GUÍA: SR. CRISTIAN GUEVARA CUE Y
SRA. MARCELA MUNIZAGA MUÑOZ

ANÁLISIS DE LOS EFECTOS DE LA PANDEMIA POR COVID-19 SOBRE LA MOVILIDAD
DE LOS USUARIOS DEL TRANSPORTE PÚBLICO DE SANTIAGO, A PARTIR DE DATOS
DE TARJETAS INTELIGENTES

La pandemia por COVID-19 generó cambios sustanciales en los patrones de movilidad que caracterizaban a las ciudades, impactando al transporte público, el cual no ha alcanzado la demanda previa a la crisis sanitaria. En este contexto, resulta relevante estudiar cómo ha variado el comportamiento de los pasajeros en el periodo, determinar los factores que incidieron en la no recuperación de los usuarios y analizar su posible proyección en el largo plazo. Para ello, se utiliza información de las transacciones con tarjetas inteligentes en Santiago de Chile durante la pandemia, las cuales ofrecen una oportunidad única para recopilar datos reales y granulares en tiempo y espacio. Específicamente, se usaron seis cortes temporales de los años 2020 y 2021.

En un primer análisis agregado de los patrones de movilidad, se muestra el impacto del COVID-19 sobre el transporte público. Al respecto, en los inicios de la pandemia se evidencia una caída del 86% en la demanda, mientras que a fines del año 2021 esta se recupera parcialmente registrando un 23% menos que la situación base. Se observa una reducción en la proporción de usuarios frecuente del transporte público (39% a 33%) y se detectan diferencias en la recuperación de la movilidad de los pasajeros matutinos, de acuerdo con la zona de residencia imputada; hay áreas que registran una caída permanente, mientras que otras superan los niveles previos.

En una segunda etapa se utilizan modelos de regresión lineal para identificar factores que impactan al transporte público en el corto, mediano y largo plazo de la emergencia. Se usa como variable dependiente la no recuperación de la demanda, y como variables explicativas a factores sociodemográficos, cuarentenas, educación, accesibilidad al transporte y trabajo. Los resultados arrojan variables significativas para explicar la no recuperación de los usuarios, presentando un efecto en todos los periodos analizados, como el nivel de ingreso por hogar. Se identifican también variables cuyo impacto es inmediato, como la proporción de la población adulta, y la proporción de la población que trabaja en educación. Finalmente, se tienen variables que adquieren significancia con el transcurso de la pandemia, como el número de ciclovías, el número de servicios de bus, la presencia de estaciones de metro y tren, y la proporción de la población joven. De los hallazgos se generan propuestas a las autoridades con el objetivo de afrontar los desafíos impuestos por la pandemia. Se recomienda fomentar la intermodalidad entre el transporte público y los ciclos, incrementar la inversión en infraestructura, con foco en mejorar la accesibilidad y densificar sectores con conectividad deficiente, y evaluar la implementación de tarifas diferenciadas.

*Dedicado a ti, que eres capaz de lograr
todo lo que te propongas*

*“Mantener la calma en la tempestad,
siempre en equilibrio y en vencer
pensar”*

Agradecimientos

Hace tres años, cuando tomé la decisión de entrar al magíster, no dimensioné todo lo que significaría para mí. Implicó dejar muchas cosas de lado, postergar planes y ausentarme, siendo que lo más me da vida es estar junto a mi gente. Es por ello que quiero agradecer a cada persona que fue parte de este camino, sin ustedes no lo habría logrado.

Agradezco a Alberto, mi compañero, amigo y amor. Gracias por no soltar mi mano, por quedarte conmigo aún en los días más duros, ser paciente y comprensivo. Gracias por confiar en mí, no permitirme abandonar y levantarme cuando me sentí abrumada. Gracias por ser mi cable a tierra, regalóarme con helados, cubrirme en las labores de casa, escuchar mis ideas, sacarme sonrisas y darme el más cálido refugio junto al Menqui.

Quiero agradecer a mi madre por enseñarme a ser constante y luchar por mis metas hasta alcanzarlas. Gracias por iluminar mi camino con tu fortaleza, eres un ejemplo de resiliencia. Agradezco también a mi hermana por su apoyo incondicional, comprenderme y aguantar mi humor en los días difíciles. Gracias a mi Otto por cada lengüetazo y cariño que levantó mi ánimo. Gracias a mis angelitos que me cuidan desde arriba, a mi abuelita y mi tata, por enviarme tranquilidad y luz. Esto también es para ustedes.

Gracias a mis amigos por su apoyo, cariño y compañía. Cami, Negra, Cucha, Osito, Jenny, Muri, Tami, Diego, Yerko, Marchi, Gonzalo, Dani, Cami, Mayo y Yani. Agradezco su preocupación y las buenas vibras que me entregaron. Gracias por las juntas y viajes, por los consejos, las risas y por regalarme momentos únicos.

Gracias al fútbol y al crossfit por sacarme de días grises, motivarme a ser mejor y enseñarme que con trabajo y constancia todo es posible. Agradezco a la Salo por su apoyo, las comidas y preocupación que siempre ha mostrado. Gracias a mi equipo Puntete y Adentro y a la comunidad Yafun, por hacerme olvidar mis preocupaciones y recargarme de energías.

Gracias a mis compañeras y compañeros de EFE, sobre todo a Barb y Vale, por el apoyo y comprensión que me mostraron durante el año 2022. Me ayudaron a recordar la importancia del trabajo en equipo y a recuperar la motivación por mi profesión.

Finalmente, quisiera agradecer a los profesores Ángelo Guevara y Marcela Munizaga, por guiarme en mi trabajo de tesis. Existieron meses donde no supieron de mí y aun así, me entendieron y aconsejaron. Gracias por la confianza depositada y la disposición que siempre tuvieron para que lográramos sacarlo adelante.

Tabla de contenido

Capítulo 1: Introducción	1
1.1. Motivación	1
1.2. Objetivos	3
1.2.1. Objetivo general	3
1.2.2. Objetivos específicos	3
1.3. Estructura de la tesis	3
Capítulo 2: Estado del Arte.....	5
2.1. Datos pasivos en transporte público	5
2.2. Indicadores de movilidad en base a datos pasivos.....	11
2.3. Impacto del COVID-19 en la movilidad.....	15
2.4. COVID-19 y transporte público	21
2.5. Modelos econométricos	28
2.5.1. Regresión lineal múltiple.....	28
2.5.2. Regresión espacial	30
Capítulo 3: Metodología y Datos	33
3.1. Descripción general de la metodología.....	33
3.2. Contexto.....	37
3.2.1. Sistema de transporte público en Santiago de Chile.....	37
3.2.2. COVID-19 en Santiago de Chile	42
3.3. Recopilación y generación de datos.....	50
3.4. Descripción de los cortes temporales en estudio	52
Capítulo 4: Análisis Agregado de Patrones de Movilidad.....	53
4.1. Análisis de transacciones	53
4.2. Análisis de viajes	61
4.3. Análisis de tarjetas del sistema	62
4.4. Análisis espacial a nivel comunal	70
4.5. Análisis espacial a partir de estimación de zona de residencia.....	75

Capítulo 5: Análisis en base a Modelos de Regresión Lineal	78
5.1. Construcción de variables	79
5.1.1. Variable explicada	79
5.1.2. Variables explicativas	83
5.1.3. Hipótesis de modelación.....	104
5.2. Resultado de los modelos de regresión lineal mediante MCO	105
5.3. Resultados de los modelos de regresión espacial	115
5.4. Análisis comparativo de modelos	120
5.5. Modelos finales.....	125
5.6. Importancia relativa de los parámetros	126
Capítulo 6: Conclusiones y Recomendaciones.....	128
6.1. Conclusiones	128
6.2. Recomendaciones	131
6.3. Limitaciones del trabajo y líneas futuras de investigación	133
Bibliografía.....	135

Índice de Tablas

Tabla 2.1: Resumen estado del arte sobre datos pasivos en transporte público	11
Tabla 2.1: Resumen estado del arte sobre indicadores de movilidad en transporte público	14
Tabla 2.1: Resumen estado del arte sobre el impacto del COVID-19 en la movilidad.....	19
Tabla 2.2: Resumen estado del arte sobre el impacto del COVID-19 en el transporte público	25
Tabla 3.1: Características sistema de buses Red	38
Tabla 3.2: Características sistema de Metro de Santiago	39
Tabla 3.3: Características servicio de Tren Estación Central-Nos	39
Tabla 3.4: Descripción Plan Paso a Paso.....	43
Tabla 3.5: Descripción de variables relevantes en bases de datos de transacciones en transporte público	51
Tabla 3.6: Definición cortes temporales a estudiar	52
Tabla 4.1: Transacciones registradas por día de la semana y corte temporal.....	53
Tabla 4.2: Transacciones registradas por modo, tipo de día y corte temporal	57
Tabla 4.3: Transacciones con bajada estimada y porcentaje de éxito, por día de la semana y corte temporal	59
Tabla 4.4: Número de zonas pagas en operación, por tipo de día y corte temporal.....	60
Tabla 4.5: Total de viajes por día de la semana y corte temporal	61
Tabla 4.6: Total de tarjetas por día de la semana y corte temporal	62
Tabla 4.7: Total de tarjetas diferentes en la semana por corte temporal	67
Tabla 4.8: Total de usuarios por tipo y corte temporal, a partir de la frecuencia con la que viaja	69
Tabla 4.9: Total de tarjetas con zona de residencia imputada, por día de la semana y corte temporal	75
Tabla 5.1: Estadísticos descriptivos iniciales del indicador de recuperación movilidad de usuarios del transporte público en la mañana	80
Tabla 5.2: Estadísticos descriptivos finales del indicador de recuperación movilidad de usuarios del transporte público en la mañana	83
Tabla 5.3: Definición del nivel de ingreso a partir del ingreso promedio líquido mensual por hogar	84
Tabla 5.4: Descripción variable de tipo dummy asociada al nivel de ingreso promedio mensual por hogar	86
Tabla 5.5: Estadísticos descriptivos de la proporción por género de la población.....	87
Tabla 5.6: Estadísticos descriptivos de la distribución por grupo etario	91
Tabla 5.7: Estadísticos descriptivos de los días corridos en cuarentena	93
Tabla 5.8: Estadísticos descriptivos de la proporción de la población en educación formal	95

Tabla 5.9: Estadísticos descriptivos de la tasa de motorización por hogar	96
Tabla 5.10: Estadísticos descriptivos del número de ciclovías existentes.....	97
Tabla 5.11: Descripción variable de tipo dummy asociada a la existencia de estaciones de metro o tren	98
Tabla 5.12: Estadísticos descriptivos del número de servicios de bus	100
Tabla 5.13: Estadísticos descriptivos de la proporción de la población que trabaja en los rubros de la industria, construcción, comercio y educación.....	103
Tabla 5.14: Influencia esperada de las variables explicativas sobre la recuperación de la movilidad de los usuarios del transporte público en la mañana	104
Tabla 5.15: Estimación de modelos de regresión lineal múltiple con indicador Recpm1, t, por corte temporal	111
Tabla 5.16: Estimación modelos de error espacial con indicador Recpm1,t, por corte temporal.....	116
Tabla 5.17: Estimación modelos regresivos cruzados con indicador Recpm1,t, por corte temporal	118
Tabla 5.18: Comparación de parámetros modelos de regresión lineal y espacial, corte temporal mayo 2020	120
Tabla 5.19: Comparación de parámetros modelos de regresión lineal y espacial, corte temporal julio 2020.....	121
Tabla 5.20: Comparación de parámetros modelos de regresión lineal y espacial, corte temporal nov 2020	122
Tabla 5.21: Comparación de parámetros modelos de regresión lineal y espacial, corte temporal julio 2021	123
Tabla 5.22: Comparación de parámetros modelos de regresión lineal y espacial, corte temporal nov 2021	124
Tabla 5.23: Modelos finales estimados, con indicador Recpm1, t, por corte temporal	125
Tabla 5.24: Coeficientes estandarizados modelos de regresión con indicador Recpm1, t, por corte temporal	126
Tabla 5.25: Variables significativas por corte temporal, agrupadas por tipo y en orden decreciente de importancia	127

Índice de Ilustraciones

Figura 3.1: Diagrama de la metodología general, etapa 1	35
Figura 3.2: Diagrama de la metodología general, etapa 2	36
Figura 3.3: Distribución geopolítica comunas de Santiago	37
Figura 3.4: Distribución de viajes diarios en Santiago por modo de transporte.....	38
Figura 3.5: Evolución anual de las transacciones y viajes en transporte público de Santiago	40
Figura 3.6: Evolución anual de las transacciones en transporte público de Santiago, por modo..	40
Figura 3.7: Evolución trimestral del índice de evasión en buses de Santiago.....	41
Figura 3.8: Evolución temporal de la movilidad, para diferentes comunas de Santiago, periodo 2020 - 2021	45
Figura 3.9: Evolución del porcentaje de personas con trabajo a distancia, periodo 2020 - 2021 .	47
Figura 3.10: Evolución mensual de las transacciones y viajes en transporte público de Santiago	49
Figura 3.11: Evolución del promedio mensual de usuarios del sistema de transporte público de Santiago	49
Figura 4.1: Perfil horario de transacciones por tipo de día y corte temporal	55
Figura 4.2: Comparación de los perfiles horarios de transacciones, cortes temporales de marzo 2020 y noviembre 2021	56
Figura 4.3: Transacciones por modo, tipo de día y corte temporal	58
Figura 4.4: Distribución del uso de tarjetas por cantidad de viajes diarios, tipo de día y corte temporal	64
Figura 4.5: Proporción de tarjetas por cantidad de viajes diarios y corte temporal – laboral	65
Figura 4.6: Proporción de tarjetas por cantidad de viajes diarios y corte temporal – sábado	66
Figura 4.7: Proporción de tarjetas por cantidad de viajes diarios y corte temporal – domingo	66
Figura 4.8: Distribución del número de días a la semana con viajes por corte temporal	68
Figura 4.9: Distribución de tarjetas de acuerdo con el número de cortes temporales en los que aparece	69
Figura 4.10: Distribución espacial de las transacciones por comuna y corte temporal - laboral ..	71
Figura 4.11: Distribución espacial de las transacciones por comuna y corte temporal - sábado ..	72
Figura 4.12: Distribución espacial de las transacciones por comuna y corte temporal - domingo	73
Figura 4.13: Distribución espacial de las tarjetas con su primera validación del día en la mañana, agrupadas por comuna y corte temporal - laboral	77
Figura 5.1: Representación de los distritos censales y su división comunal	80
Figura 5.2: Histogramas de la variable dependiente, por corte temporal	81
Figura 5.3: Comportamiento espacial y evolución temporal de la recuperación de la movilidad de los usuarios del transporte público en la mañana	82
Figura 5.4: Distribución espacial del ingreso promedio líquido mensual por hogar.....	84

Figura 5.5: Distribución espacial del nivel de ingreso por hogar.....	85
Figura 5.6: Distribución espacial de la proporción de mujeres	87
Figura 5.7: Distribución espacial de la proporción de la población con edad entre 0 y 14 años ..	88
Figura 5.8: Distribución espacial de la proporción de la población con edad entre 15 y 29 años	89
Figura 5.9: Distribución espacial de la proporción de la población con edad entre 30 y 44 años	90
Figura 5.10: Distribución de la proporción de la población con edad entre 45 y 59 años	91
Figura 5.11: Distribución espacial de los días corridos en cuarentena, corte temporal mayo 2020	92
Figura 5.12: Distribución espacial de los días corridos en cuarentena, corte temporal julio 2020	93
Figura 5.13: Distribución espacial de la proporción de la población que asiste a la educación formal	94
Figura 5.14: Distribución espacial de la tasa de motorización por hogar.....	95
Figura 5.15: Distribución espacial de las ciclovías existentes.....	96
Figura 5.16: Distribución espacial de las estaciones de metro y tren.....	97
Figura 5.17: Distribución espacial de los servicios de transporte público mediante bus, operados por las Unidades de Negocios U2 Subus Chile y U3 Buses Vule.....	98
Figura 5.18: Distribución espacial de los servicios de transporte público mediante bus, operados por las Unidades de Negocios U4 Voy Santiago SPA y U5 Metbus	99
Figura 5.19: Distribución espacial de los servicios de transporte público mediante bus, operados por las Unidades de Negocios U6 Redbus Urbano y U7 STP.....	99
Figura 5.20: Distribución espacial de la proporción de la población que trabaja en el rubro industrial.....	100
Figura 5.21: Distribución espacial de la proporción de la población que trabaja en el rubro de la construcción.....	101
Figura 5.22: Distribución espacial de la proporción de la población que trabaja en el rubro del comercio	102
Figura 5.23: Distribución espacial de la proporción de la población que trabaja en el rubro de la educación.....	103
Figura 5.24: Histogramas de residuos y gráficos de probabilidad normal de tipo P-P, por corte temporal.....	106
Figura 5.25: Diagramas de dispersión, por corte temporal.....	108

Capítulo 1: Introducción

1.1. Motivación

La movilidad humana ha sido un área de investigación recurrentemente estudiada por la literatura en las últimas décadas. La disponibilidad de datos granulares y georreferenciados permite, por un lado, conocer y comprender los patrones de movimiento que siguen las personas. A su vez, aportan en la toma de decisiones operacionales y de planificación, por lo cual resultan de interés para las autoridades.

Cualquier interrupción que ocasione un cambio en la oferta o demanda de transporte repercute directamente en los patrones de viaje y actividades de las ciudades modernas. En particular, la rápida propagación del virus infeccioso SARS-CoV-2 desde los inicios del año 2020, conocido comúnmente como COVID-19, generó una crisis sanitaria global, marcando un antes y un después en la vida de las personas.

El 11 de marzo de 2020 la Organización Mundial de la Salud (OMS) declaró la pandemia mundial, llevando a los gobiernos a restringir los desplazamientos y actividades para combatirla. Medidas como la suspensión de clases en establecimientos educacionales, teletrabajo en algunos rubros, cierre de servicios y comercios no esenciales, cuarentenas parciales y totales por áreas, y distanciamiento social fueron implementadas para evitar aglomeraciones.

A esto se suma la opción individual de viajar menos que adoptaron algunas personas, con el objetivo de reducir su exposición al virus. La limitación de la movilidad afectó significativamente a los sistemas de transporte y ocasionó, entre múltiples impactos, una reducción en el número de desplazamientos diarios.

Diversas investigaciones realizadas a la fecha muestran cambios importantes en la movilidad espacial y temporal de las personas, así como también en la elección de modo. Por un lado, los modos individuales son preferidos por sobre los medios masivos, donde el transporte privado y la bicicleta se escogen en desmedro del transporte público, cuya demanda se ha recuperado lentamente (Abdullah et al., 2020; De Haas et al., 2020; Bucsky, 2020; Molloy et al., 2021; Kellermann et al., 2022).

Por otra parte, el trabajo desde el hogar y las compras online se han visto favorecidas ante las restricciones de desplazamiento impuestas por las autoridades. En concreto, diferentes efectos han sido identificados, dependientes del nivel de socioeconómico, donde las personas con ingresos más altos tienen una mayor reducción en el número de viajes diarios, en comparación con la situación previa a la crisis sanitaria (Astroza et al., 2020; Liu et al., 2020; Molloy et al., 2021).

Finalmente, el modo más afectado sin duda ha sido el transporte público, evidenciándose una menor demanda, una reducción de la distancia recorrida y de la frecuencia de viaje (Bucsky, 2020; Kellermann et al., 2022). En la literatura se han contemplado variables de género, edad, educación y nivel de ingreso para explicar la caída en el número de pasajeros desde la llegada del COVID-19 (Willbüry et al., 2020; Hu y Chen, 2021; Brough et al., 2021; Basnak et al., 2022). La percepción de temor al contagio en el transporte público también resulta un factor relevante de considerar (Qi et al., 2021).

De acuerdo con las indicaciones entregadas por el Gobierno de Chile, el 1 de octubre de 2022 el país pasará a fase de “Apertura” por primera vez en más dos años, levantando restricciones de aforo y uso de mascarilla. Con ello, se comienza a dejar atrás la pandemia por COVID-19, sin embargo, existe una serie de desafíos para el transporte público que aún no son resueltos.

Los efectos económicos y sociales de la pandemia sobre el transporte público abarcan consecuencias en la movilidad sostenible, en la viabilidad financiera y en la equidad social del sistema (Tirachini y Cats, 2020). Por ende, comprender los cambios sobre la movilidad y comportamiento de los usuarios en transporte público debido a la emergencia sanitaria, y cuestionarse cuáles de estos tendrán un efecto significativo a corto, mediano y largo plazo en la ciudad de Santiago de Chile, permitirá generar propuestas que fomenten la restauración del transporte público en la sociedad.

Para dar respuesta al problema identificado, en el presente trabajo de tesis se utilizan los registros de transacciones de tarjetas inteligentes en el sistema, en distintos cortes temporales, con los que se cuantificará el impacto de la pandemia en el caso de estudio. Adicionalmente, se estimarán modelos econométricos, a partir de los cuales se analizará la no recuperación en el número de pasajeros y se determinará la contribución de factores sociodemográficos, educacionales, de trabajo y de accesibilidad al transporte en la caída observada.

1.2. Objetivos

1.2.1. Objetivo general

El objetivo general de esta tesis es caracterizar el impacto de la pandemia por COVID-19 sobre los patrones de movilidad de los usuarios de transporte público de la ciudad de Santiago de Chile y determinar los factores que inciden en la no recuperación de los pasajeros del sistema, mediante el uso de bases de datos pasivos.

1.2.2. Objetivos específicos

- Realizar una revisión de la literatura sobre patrones de conducta de los usuarios de transporte público, indicadores descriptivos de movilidad e impacto de la pandemia en los sistemas de transporte urbano.
- Efectuar un análisis descriptivo agregado de los datos pasivos recopilados a través de transacciones con tarjetas inteligentes, para caracterizar los viajes y el comportamiento de los usuarios del transporte público en seis cortes temporales, representativos de diferentes momentos de la pandemia por COVID-19.
- Comparar los resultados de los cortes temporales considerando diversas dimensiones, entre ellas, temporal y espacial, para identificar los efectos de la emergencia sanitaria, en distintos niveles de agregación, sobre la movilidad de los usuarios de transporte público.
- Determinar variables estadísticamente significativas en explicar la no recuperación de la movilidad de los usuarios de transporte público debido a la pandemia por COVID-19, a partir de la estimación de modelos econométricos.
- Cuantificar el impacto, explicar cómo los factores identificados contribuyen en incrementar o reducir el número de pasajeros del sistema en los cortes temporales de pandemia, y analizar su posible proyección en el largo plazo.

1.3. Estructura de la tesis

La estructura de la tesis considera en el Capítulo 2 una revisión del estado del arte en manejo de datos pasivos en transporte público y caracterización de indicadores de movilidad. También se presenta una revisión de la literatura de modelos econométricos, junto con el estudio del impacto de la pandemia por COVID-19 en los patrones de movilidad y en el uso del transporte público.

En el Capítulo 3 se expone la metodología del trabajo realizado y se describen los datos recopilados que se utilizan en los apartados posteriores. Adicionalmente, se caracteriza al sistema de transporte público de la ciudad de Santiago de Chile y el desarrollo de la emergencia sanitaria en ella.

En el Capítulo 4 se efectúa un análisis agregado de los patrones temporales y espaciales de movilidad, aplicando técnicas estadísticas y de visualización. Se caracteriza el comportamiento de los usuarios del transporte público, basado en el uso de datos pasivos del sistema, se realiza un análisis comparativo y se estudia la evolución de la movilidad en el transcurso de la pandemia.

En el Capítulo 5 se presentan las variables independientes y dependiente construidas que serán incorporadas en la modelación. Posteriormente se muestran los resultados de la estimación de modelos econométricos y se elaboran análisis sobre el efecto de cada factor considerado en el fenómeno estudiado.

Por último, en el Capítulo 6 se exponen las conclusiones obtenidas tras el desarrollo de este trabajo, se discuten limitaciones encontradas, implicancias y recomendaciones dadas para el futuro lector.

Capítulo 2: Estado del Arte

El impacto de la pandemia por COVID-19 sobre el transporte público ha sido un tema de interés global y ampliamente estudiado en la literatura durante los últimos años. Por tanto, en el capítulo 2 se exponen y analizan críticamente las líneas de investigación más destacadas que sustentan y complementan el presente trabajo.

En primer lugar, se muestra una síntesis del estado del arte asociado al uso de datos pasivos en transporte público, identificando sus principales características, virtudes y limitaciones. Se incluyen definiciones básicas y metodologías claves que enriquecen la información.

Luego, se exponen algunas de las múltiples aplicaciones de datos pasivos que han sido implementadas en otros estudios con el fin de caracterizar patrones de viajes y el comportamiento de los usuarios del transporte público, mediante indicadores temporales y espaciales de movilidad.

Posteriormente, se presentan investigaciones enfocadas en analizar el impacto de la crisis sanitaria sobre la movilidad, dando énfasis a su efecto sobre el transporte público. Se agrupan según los datos usados, la metodología aplicada, las variables consideradas y los hallazgos obtenidos. Por último, se entrega un breve marco teórico sobre los modelos econométricos que serán utilizados para representar el fenómeno en estudio.

2.1. Datos pasivos en transporte público

En las últimas décadas, diferentes técnicas de recopilación de datos masivos han sido exploradas. Sensores y dispositivos incorporados en smartphones, registros de llamadas telefónicas, aplicaciones móviles, cámaras de tráfico, sistemas de cobro electrónico de peajes en autopistas y el uso de tarjetas inteligentes en medios de transporte, son solo algunas de las variadas fuentes de información que se disponen en la actualidad. Específicamente, los sistemas automatizados de cobro de tarifas con tarjetas inteligentes se encuentran ampliamente implementados a nivel global.

En concreto, los datos pasivos, alimentados por las transacciones de pago mediante tarjetas inteligentes y el equipamiento de GPS en buses, son una herramienta tecnológica de utilidad y bajo costo para extraer información masiva del sistema. Esta información es de gran valor para el análisis, planificación y regulación de los sistemas de transporte público de las ciudades, realizado por investigadores, entidades reguladoras y empresas operadoras del servicio.

Dos conceptos importantes de diferenciar para comprender la mayoría de las metodologías detrás de los datos pasivos son los de “etapa” y “viaje”. En primer lugar, la etapa de viaje se asocia al movimiento de un pasajero en un mismo vehículo, desde que aborda este hasta su posterior

bajada. Por otro lado, un viaje corresponde al desplazamiento desde un origen hasta un destino donde el usuario realiza una actividad. Por lo tanto, un viaje puede estar formado por una o más etapas, dependiendo del número de trasbordos y/o cambios de modo que el usuario efectúe (Devillaine et al., 2012; Espinoza, 2017)

Múltiples autores han identificado diversos usos para estos datos, cuya ventaja respecto a métodos tradicionales existentes, como las encuestas o mediciones, es que permiten trabajar con muestras más grandes y analizar el comportamiento durante periodos de tiempo más extensos (Bagchi y White, 2005). Entre ellos se encuentran:

- *Análisis temporales de la demanda:* Cálculo de estadísticas de pasajeros en una escala de tiempo. Considera la elaboración de perfiles horarios y diarios, desagregados por modo de transporte o por tipo de tarjeta. Permiten caracterizar y clasificar a los pasajeros, estudiar la frecuencia de uso del transporte público en un periodo determinado y la permanencia de los usuarios en el sistema (Munizaga et al., 2012).
- *Diagramas espaciales de la demanda:* Cálculo de estadísticas de pasajeros en una escala espacial. Contempla la estimación de perfiles de pasajeros que embarcan en cada paradero, para diferentes niveles de desagregación temporal. Permiten evaluar el impacto de la creación, eliminación o modificación de rutas de buses (Gschwender et al., 2016).
- *Diagramas espacio-temporal de los buses:* Se obtienen, a partir de los pulsos del GPS, perfiles de velocidad comercial para cada ruta. Estas visualizaciones facilitan la detección del apilamiento de buses o problemas de infraestructura (Gschwender et al., 2016).
- *Medición de variables asociadas a la calidad del sistema:* Se realiza seguimiento a la regularidad, tiempos de espera, tiempos de viaje y su variabilidad, entre otros (Gschwender et al., 2016).

A su vez, Pelletier et al. (2011) realiza una revisión de las principales herramientas desarrolladas y las agrupa en tres niveles de gestión: estratégico (planificación a largo plazo), táctica (ajustes del servicio y desarrollo de la red) y operativa (estadísticas de usuarios e indicadores de rendimiento).

Existen antecedentes que no son posibles de recopilar, o bien se encuentran incompletos, al usar datos de tarjetas inteligentes. Algunos de ellos son el propósito del viaje, características de los usuarios (lugar de residencia, género, edad) en sistemas donde la tarjeta no es personalizada, estimación de la ubicación y hora de bajada en los casos que no requieren validar la tarjeta al término del viaje, percepción o satisfacción de los pasajeros, entre otros. Respecto al registro parcial de viajes, esto dependerá de la tasa de penetración que tenga el medio de pago en el sistema, así como de los niveles de evasión existentes (Bagchi y White, 2005; Munizaga et al., 2012).

Para abordar dichas limitaciones, se han elaborado diversas metodologías, que requieren un post procesamiento de los datos pasivos, para enriquecer la información extraída directamente de las transacciones de pago (Trépanier et al., 2007; Zhao et al., 2007; Chu y Chapleau, 2008; Munizaga y Palma, 2012; Devillaine et al., 2012; Chakirov y Erath, 2012; Lee y Hickman, 2014; Munizaga et al., 2014; Li et al., 2015; Amaya et al., 2018; Alsger et al., 2018; Munizaga et al. 2020).

En efecto, en Munizaga y Palma (2012) se plantea una metodología para construir matrices origen destino de transporte público, para cualquier desagregación espacio temporal, basado en las transacciones mediante tarjetas inteligentes y sistema de posicionamiento GPS implementado en la ciudad de Santiago, Chile. Una de las principales contribuciones del trabajo mencionado fue la elaboración de un método para estimar el tiempo y la posición de bajada de cada etapa, con lo cual se logra reconstruir la cadena de viajes de los usuarios detrás de cada tarjeta inteligente.

El método de estimación de bajada elaborada por Munizaga y Palma (2012) considera principios básicos de investigaciones anteriores, pero incorpora restricciones adicionales y modifica la función objetivo (Barry et al., 2002; Zhao et al., 2007; Trepanier et al., 2007). A partir de ella se logra estimar la bajada para más del 80% de las transacciones del sistema, efectuadas en semanas de marzo 2009 y junio 2010.

Con respecto al algoritmo implementado, en términos generales consiste en seguir la cadena de viajes de una tarjeta e identificar la posición de bajada (paradero o estación de metro) a partir del lugar y hora en el que se realiza la próxima validación, considerando que cada tarjeta equivale a un usuario. Para la última transacción del día, se supone que el destino del viaje se encuentra cerca del origen del primer viaje del día. Por otro lado, si la tarjeta registra un único viaje en el día, no es posible realizar la inferencia.

En el caso de los buses, la estimación posición-tiempo bajada se busca a lo largo de la trayectoria del bus, conocida gracias al sistema GPS, de forma tal que se minimice el tiempo generalizado de viaje, sujeto a que la distancia entre la posición de bajada y la posición del próximo embarque sea menor a la distancia que la persona está dispuesta a caminar (fijado en 1000 metros). La función de tiempo generalizado depende del tiempo de viaje en el vehículo, y del tiempo de caminata entre la posición de bajada y la próxima subida. Si el problema de minimización no tiene solución dentro del umbral de distancia máxima establecida, se supone que falta un segmento de viaje, se está usando otro modo o tarjeta, por lo que no es posible estimar el punto de bajada (Munizaga y Palma, 2012).

Para los viajes en metro, la estación de bajada se estima como la más próxima, en distancia, al sitio donde se realiza la siguiente transacción de subida, dentro de una circunferencia definida por la distancia caminable. Dado que los trenes de metro no cuentan con GPS, se requiere estimar el tiempo de bajada y la ruta utilizada. En concreto, a partir de la estación de bajada se estima la ruta seguida por el usuario, aplicando el procedimiento de ruta más corta de Dijkstra. Luego el

tiempo de viaje entre estaciones, el tiempo de espera y de caminata dentro de la estación se obtienen del plan operativo de Metro. Por tanto, el tiempo total, que permite estimar el instante en que ocurre la bajada, equivale a la suma de los tiempos anteriores.

Finalmente, en el caso de las zonas pagas, que corresponden a paraderos donde el usuario debe pagar su pasaje antes de subir al bus, se requiere resolver el problema adicional de determinar el servicio de bus que utilizó el pasajero. Para ello, en primer lugar se identifican todas las rutas que se detienen en la estación abordada y tienen al menos una parada a poca distancia de las coordenadas de la siguiente transacción realizada por el usuario. Posteriormente, si dos o más rutas cumplen con el criterio anterior, se aplica el método propuesto por Chriqui y Robillard (1975) para definir un conjunto de líneas comunes, lo cual requiere resolver el problema de minimización del tiempo generalizado. Encontrado el conjunto, se asume que el usuario subirá al primer bus de las opciones de líneas comunes que pase por el paradero, luego de efectuar la transacción. Con ello, se asigna el servicio, se infiere el vehículo utilizado y por ende, es factible estimar las coordenadas y tiempo de bajada siguiendo el procedimiento descrito para los buses.

Al estimar las bajadas asociadas a cada transacción en bus, metro o zona paga, Munizaga y Palma (2012) utilizan reglas temporales para distinguir los viajes de las etapas, entendiendo que un viaje puede estar formado por una o más etapas. Luego, si una persona permanece por más de 30 minutos en un punto, es decir, el tiempo entre la bajada estimada y la siguiente transacción supera el umbral, entonces se considerará que corresponde al destino de un viaje y el usuario realizará una actividad en ese sitio. En caso contrario, es un punto de transferencia.

Construidas las estructuras de viajes de cada usuario, se elaboran las matrices origen destino de transporte público. En casos donde la información del viaje queda incompleta, por ejemplo, no se logró estimar el destino, o se desconoce el origen y el destino, o bien hay viajes que no fueron detectados porque faltan transacciones intermedias (evasión), se aplican factores de corrección sobre las matrices (Munizaga y Palma, 2012).

Por otro lado, en Li et al. (2015) se presenta un método para predecir la ubicación del hogar y del trabajo, usando datos de tarjetas inteligentes del transporte público de Singapur en el año 2011. Para ello, en primer lugar realizan un preprocesamiento de los registros, eliminando viajes incompletos y tarjetas con pocas transacciones, y considerando que si el lapso entre dos transacciones consecutivas es menor a 45 minutos, entonces las estaciones corresponden a posiciones de trasbordo. Al excluir registros de usuarios con viajes ocasionales, se obtiene una muestra de 118.281 tarjetas que efectuaron viajes al menos dos veces al día, durante 61 de 90 días de datos.

El segundo paso de la metodología consiste en seleccionar posiciones candidatas y evaluar la probabilidad de que la ubicación se asocie al lugar de trabajo o de residencia., usando criterios como la duración de la actividad o el número de veces que el pasajero visita un lugar. Posteriormente se seleccionan los mejores 5 candidatos a ser ubicaciones del hogar y trabajo. Para

escoger uno de ellos se utilizan criterios de regularidad, considerando que los viajes son tratados como series de tiempo, y se efectúa un análisis espectral identificando los patrones de desplazamiento más probables. Finalmente, se diferencia entre el hogar y el lugar del trabajo a partir de los tiempos de acceso observados durante fines de semana y festivos, suponiendo que los usuarios trabajan preferentemente a lo largo de la semana (Li et al., 2015).

Paralelamente, en Amaya et al. (2018) proponen un método de estimación de la zona de residencia de los usuarios del transporte público. Para ello, ocupan las transacciones matutinas de pasajeros frecuentes del sistema en de Santiago de Chile. En específico, consideran una muestra de 888.970 tarjetas inteligentes observadas al menos tres días de una semana tipo de abril del 2013, que muestran regularidad espacial en la transacción matutina.

La metodología desarrollada por Amaya et al. (2018) supone que los pasajeros frecuentes del sistema usan transporte público para la mayoría de sus viajes, por lo que la primera transacción de la mañana ocurre probablemente cerca de su zona de residencia.

Para la muestra de usuarios frecuentes, estudian la distribución espacial de sus primeras transacciones, es decir, aquellas efectuadas entre las 04:00 y 12:00 horas del mediodía, en los días que se registraron viajes bajo esta condición. Calculan el centro de gravedad de las coordenadas de esas primeras transacciones matutinas y luego, estiman la distancia (d_k) entre la posición donde se realizaron las validaciones y el centro de gravedad, para cada día. Si la mayor distancia d_k es menor que la distancia caminable, entonces la tarjeta se asocia con la zona de residencia correspondiente a la zona donde se registraron esas transacciones. Cabe señalar que con esta aplicación fue factible estimar información socioeconómica de los pasajeros, lo que posibilitó la elaboración de análisis de patrones de viaje y uso del tiempo (Amaya et al., 2018).

Respecto a la estimación del propósito de viaje, Devillaine et al. (2012) desarrollan y aplican una metodología que distingue entre viajes y actividades, basado en criterios temporales, espaciales y patrones de conducta, para las ciudades de Santiago, Chile y Gatineau, Canadá. Esta consta de dos etapas; en la primera, se establecen patrones de conducta que permitan identificar cuando el tiempo entre dos transacciones corresponde a un trasbordo y cuando a la ejecución de una actividad en el destino del viaje. Los criterios consideran características asociadas al comportamiento de cada individuo y atributos propios del sistema de transporte público. Algunas de las condiciones que permiten reconocer actividades son: tiempos de trasbordos superiores a 30 minutos, transacciones consecutivas en la misma estación de metro o bien en el mismo servicio-sentido de bus y selección de rutas muy largas en comparación a la distancia euclidiana entre el origen y el destino.

Una vez que se ha asociado la fecha, hora y duración a las actividades detectadas, el segundo paso consiste en estimar para cada actividad un cierto propósito (trabajo, estudio, hogar u otros). Los criterios usados en el caso de la ciudad de Santiago se basan en Olguin et al. (2009) y se diferencian entre días laborales y fines de semana. Para distinguir los propósitos trabajo y estudio,

cuya duración se proyecta superior a las 5 horas, se utiliza el tipo de tarjeta (adulto o estudiante). Por otro lado, el propósito hogar se caracteriza porque el viaje anterior a la actividad fue el último observado en el día, es decir, corresponderá al tiempo entre la última transacción de un día y la primera transacción del día siguiente. Toda actividad restante, con duración máxima de 2 horas en día laboral y 5 horas en fin de semana, cuyo viaje anterior no fue el último del día, se les imputa el propósito otros.

De forma similar, en Lee y Hickman (2014) se propone e implementa un método para inferir el propósito del viaje a partir de los datos de transacciones en transporte público en el área metropolitana de Minneapolis-St. Paul, durante una semana tipo del mes de noviembre 2008. Esto bajo el supuesto de que los usos de suelo en áreas adyacentes a los orígenes y destinos afectan las decisiones de viaje. La metodología utiliza atributos como la información del usuario (tipo de tarjeta), información temporal (hora y duración entre transacciones) y espacial (frecuencia de las transacciones en un lugar determinado), los cuales alimentan un árbol de decisiones que, junto al uso de una serie de reglas, asigna propósitos de viaje a cada usuario (trabajo, estudio u otros).

Por último, en Munizaga et al. (2020) se presenta un método para estimar factores de corrección por evasión parcial y total de tarifas en etapas del viaje, considerando que a partir del uso directo de los datos de tarjetas inteligentes solo es factible contabilizar los viajes que fueron pagados con ella. En efecto, se aplica la metodología al caso de Santiago de Chile, utilizando en una primera etapa información adicional de la Encuestas Origen Destino de Metro de Santiago para corregir la evasión tarifaria parcial, en tramos de viaje de bus antes y después de un tramo de viaje en metro. En la segunda etapa se ocupan mediciones externas de evasión para incluir en las matrices los viajes solo de bus que son completamente evadidos. En la última etapa se corrige la evasión total en viajes de metro, a partir de la información entregada por la encuesta de metro y datos exógenos. La aplicación de factores de corrección por evasión contribuye a mejorar la obtención de las matrices origen destino de transporte público a partir de datos pasivos.

En la tabla 2.1 se resume la literatura descrita anteriormente, la cual estudia el uso de datos pasivos en transporte público, sus limitaciones y las metodologías propuestas para su enriquecimiento. Se agrupan por tipos de datos utilizados y principales contribuciones.

Tabla 2.1: Resumen estado del arte sobre datos pasivos en transporte público

Autor	Datos utilizados (ubicación)	Principales contribuciones
Munizaga y Palma (2012)	Transacciones mediante tarjetas inteligentes y sistema de posicionamiento GPS (Santiago, Chile)	Método para estimar el tiempo y posición de bajada de cada etapa
		Reconstrucción de la cadena de viajes
		Elaboración de matrices origen destino de transporte público
Li et al. (2015)	Transacciones mediante tarjetas inteligentes (Singapur)	Método para predecir la ubicación del hogar y del trabajo
Amaya et al. (2018)	Transacciones matutinas mediante tarjetas inteligentes (Santiago, Chile)	Método para estimar la zona de residencia de los usuarios
		Estimación de información socioeconómica de los pasajeros
		Análisis de patrones de viaje y uso del tiempo
Devillaine et al. (2012)	Transacciones mediante tarjetas inteligentes (Santiago, Chile / Gatineau, Canadá)	Método para distinguir entre viajes y actividades
		Estimación del propósito de viaje, basado en criterios temporales, espaciales y patrones de conducta
Lee y Hickman (2014)	Transacciones mediante tarjetas inteligentes (Minneapolis-St. Paul, Estados Unidos)	Método para inferir el propósito de viaje
Munizaga et al. (2020)	Transacciones mediante tarjetas inteligentes (Santiago, Chile)	Método para estimar factores de corrección por evasión de tarifas en etapas del viaje
		Mejoramiento de las matrices origen destino de transporte público obtenidas

Fuente: Elaboración Propia

2.2. Indicadores de movilidad en base a datos pasivos

Diversos autores han identificado el potencial de los datos pasivos para describir el comportamiento de los usuarios del transporte público, a través de la caracterización de su movilidad. En múltiples casos se ha utilizado el análisis en clusters (categorías) para clasificar en grupos a los pasajeros que presentan patrones de viaje similares. Esto facilitado por la disponibilidad de datos en diferentes periodos de tiempo, lo cual permite analizar la regularidad y variabilidad temporal de los patrones de conducta existentes.

Espinoza (2017) realiza una completa revisión de la movilidad, descrita a través de diferentes variables que se utilizan sobre registros de transacciones en transporte público. Los indicadores se clasifican en temporales, espaciales, sociodemográficas, de modo de transporte, de actividad y espaciotemporales.

Respecto a las variables temporales, cuyo objetivo es reconocer patrones de los usuarios en el tiempo, se identifica a la frecuencia de viaje, medida a través del número de viajes por día y número de días en que se realizan viajes, y a la hora de inicio del primer y último viaje del día

como los principales atributos considerados. Sobre los indicadores espaciales, se tiene a la frecuencia de uso de una parada y a la distancia de viaje, las cuales miden el uso del espacio en un área determinada. Por otro lado, las variables espaciotemporales en general trabajan con la probabilidad de retornar a un lugar visitado en una hora determinada.

Dentro de las variables sociodemográficas, la única característica de los usuarios posible de obtener directamente desde los datos de transacciones es el tipo de tarjeta o la tarifa pagada. A su vez, los indicadores de actividad se basan en describir su duración, a partir del lapso entre viajes, para inferir el propósito. Por último, las variables de modo de transporte buscan determinar las preferencias de los usuarios por algún medio, entre las cuales se encuentra el porcentaje de días con viajes exclusivamente en bus o en metro, según se desee estudiar (Espinoza, 2017).

Utsunomiya et al. (2006) estudian la variabilidad espacial del lugar de origen del primer viaje del día y los patrones de uso diario de las tarjetas inteligentes, a partir de los datos de transacciones observadas en una semana de septiembre 2004 en Chicago. Adicionalmente muestran un análisis de las distancias de acceso a la red, es decir, la distancia desde el hogar de un pasajero hasta la estación que aborda por primera vez en el día. Al contrario de otros sistemas, cuando se emiten tarjetas en Chicago se recopila información del usuario, como su nombre, dirección, número telefónico y correo electrónico, la cual queda vinculada al número de serie. El trabajo encuentra diferencias en el comportamiento de la distancia de acceso a pie y en la variabilidad del origen del primer viaje, entre modos escogidos (bus y tren) y en usuarios de distintas zonas residenciales. Se estudian también las tasas de uso del transporte público para cada día y a lo largo de la semana para obtener un indicador de regularidad y consistencia.

Por su parte, en Agard et al. (2006) presentan una metodología para caracterizar el comportamiento de los usuarios, los cuales se clasifican en adultos, estudiantes y adultos mayores basado en los tipos de tarjetas inteligentes. Para ello, se ocupan datos de validaciones por tarjeta, realizadas entre los meses de enero y abril 2005 en el sistema de transporte público de Gatineau, Quebec, Canadá. En particular, se identifican los viajes observados por semana y periodo, para cada tarjeta, a partir de la generación de variables binarias. Estas indican si el usuario realizó al menos una validación en el día de la semana y periodo del día respectivo. Luego, se buscan hábitos de viaje similares en los días de semana y durante las semanas, implementando algoritmos de clustering, y se examina la variabilidad de los grupos formados en el periodo analizado para estudiar la regularidad de los patrones.

De la aplicación del procedimiento se obtienen cuatro grupos de usuarios con conductas similares: el primer perfil se relaciona con pasajeros regulares del sistema, principalmente adultos, que viajan en horarios punta mañana y punta tarde, posiblemente por motivos de trabajo. El segundo grupo no muestra una tendencia clara, mientras que el cuarto perfil agrupa a los viajeros no frecuentes y caracteriza a gran parte de los adultos mayores. Por último, el tercer grupo también se asocia a personas con actividades regulares pero en los horarios punta mañana y punta medio día.

De manera similar, en Morency et al. (2007) se definen medidas de variabilidad espacial y temporal del uso del transporte público para varios tipos de tarjetas, a partir de datos recopilados a lo largo del año 2005 en la red de tránsito de Gatineau, Quebec, Canadá. Respecto a los indicadores de variabilidad espacial, estudian la frecuencia de uso de las paradas de bus por tipo de tarjeta. Por otro lado, la variabilidad temporal se evalúa mediante técnicas de minería de datos. En efecto, recopilan para cada tarjeta los abordajes por hora por día, aplican algoritmos de agrupamiento e identifican patrones temporales para tarjetas de clases similares. La aplicación de la metodología distingue distintos comportamientos de viaje entre los tipos de usuarios, los cuales se contrastan en el número de viajes efectuados en el día y en la hora en que se realizaron, pero también se detectan diferencias para un mismo tipo de tarjeta.

A la vez, Ma et al. (2013) proponen un procedimiento de minería de datos para modelar patrones de viaje y regularidad de los usuarios de transporte público en Beijing, China, a partir de datos de transacciones de una semana de julio 2010. La metodología consta de tres pasos; en primer lugar se recuperan las transacciones de tarjetas inteligentes de varios días, para cada pasajero identificado. Luego, usando características espaciales y temporales de los datos de transacciones se generan las cadenas de viaje de cada usuario. Por último, mediante la aplicación de algoritmos de agrupación espacial y de clustering, se analizan las cadenas de viajes para detectar patrones de viaje históricos de los usuarios y se extrae la regularidad de los patrones del pasajero. Para la agrupación se tomaron en cuenta atributos como el número de días con viajes en transporte público (pasajero frecuente), días con similar hora en la primera transacción (usuario regular), y secuencias de rutas y paraderos semejantes seguidos durante la semana. Los resultados tras aplicar el método arrojan que los usuarios regulares del transporte público (42%) viajan más de dos veces al día, mientras que aquellos con baja regularidad (41%) presentan en promedio menos de un viaje diario.

Por otro lado, en Tao et al. (2014) plantean una metodología para extraer y visualizar patrones espacio-temporales del comportamiento de viaje de los usuarios del sistema de buses de Brisbane, Queensland, Australia. Para ello, inicialmente se procesaron los datos registrados mediante tarjetas inteligentes y se reconstruyeron las trayectorias de viaje a nivel de paradero de bus. Luego, aplicando técnicas basadas en sistemas de información geográfica, se crearon mapas de flujo con el objetivo de visualizar patrones agregados a nivel de red, e identificar las principales rutas utilizadas por los pasajeros de bus y sus variaciones durante el periodo de un día. Por último, se detectaron cambios espacio-temporales de los patrones de flujo de pasajeros.

Finalmente, en El Mahrsi et al. (2017) se consideran dos enfoques para agrupar tarjetas inteligentes y extraer patrones de movilidad en el sistema de transporte público del área metropolitana de Rennes, Francia. A partir de la reconstrucción de las cadenas de viajes, en una primera instancia se estudia cómo se distribuyen en el tiempo los viajes realizados en las estaciones. El segundo enfoque construye perfiles temporales semanales de pasajeros e identifica grupos que se comportan de manera similar respecto a sus horas de embarque. Los resultados entregan la existencia de estaciones que desempeñan diferentes roles en la red, dependiendo de la hora del día

en que son usadas y su ubicación (residenciales, de trabajo, lugares de ocio y recreación, entre otros), así como también se detectan distintos comportamientos en los usuarios, en función de la frecuencia con que viajan y el tipo de tarifa.

En la tabla 2.2 se resume la literatura descrita anteriormente, la cual estudia diversos indicadores de movilidad construidos a partir de datos pasivos, que permiten caracterizar el comportamiento de los usuarios del transporte público. Se agrupan por tipos de datos utilizados e indicadores analizados.

Tabla 2.2: Resumen estado del arte sobre indicadores de movilidad en transporte público

Autor	Datos utilizados (ubicación)	Atributos de movilidad estudiados
Espinoza (2017)	Transacciones mediante tarjetas inteligentes (Santiago, Chile / Gatineau, Canadá)	Temporales (frecuencia de viaje, hora de inicio del primer y último viaje del día)
		Espaciales (frecuencia de uso de parada y distancia de viaje)
		Espaciotemporales (probabilidad de retornar a un lugar visitado en una hora determinada)
		Sociodemográficos (tipo de tarjeta)
		Actividad y propósito del viaje
		Modo de transporte y sus preferencias
Utsunomiya et al. (2006)	Transacciones mediante tarjetas inteligentes (Chicago, Estados Unidos)	Variabilidad espacial del lugar de origen del primer viaje del día
		Distancia de acceso a la red
		Tasa de uso del transporte público por día
Agard et al. (2006)	Transacciones mediante tarjetas inteligentes (Gatineau, Canadá)	Frecuencia de viaje por semana y periodo
		Regularidad de patrones de viaje
Morency et al. (2007)	Transacciones mediante tarjetas inteligentes (Gatineau, Canadá)	Frecuencia de uso de las paradas de bus por tipo de tarjeta
		Número de abordajes por hora, día y tipo de tarjeta
Ma et al. (2013)	Transacciones mediante tarjetas inteligentes (Beijing, China)	Número de días con viajes en transporte público
		Número de días con similar hora en la primera transacción
		Secuencia de rutas y paraderos semejantes seguidos durante la semana
Tao et al. (2014)	Transacciones mediante tarjetas inteligentes (Queensland, Australia)	Secuencia de rutas utilizadas por los pasajeros y sus variaciones durante un día
El Mahrsi et al. (2017)	Transacciones mediante tarjetas inteligentes (Rennes, Francia)	Perfiles temporales semanales de los viajes

Fuente: Elaboración Propia

2.3. Impacto del COVID-19 en la movilidad

La pandemia global por COVID-19 y las respectivas medidas tomadas por las autoridades para controlar su propagación han impactado de manera considerable la vida de las personas, modificando diferentes hábitos y conductas. En particular, uno de los sectores que experimentó mayores efectos fue el del transporte, viéndose reflejado en los cambios de los patrones de movilidad espaciotemporal producto de los ajustes en las actividades y viajes diarios.

Mientras algunos países tomaron medidas estrictas, otros evitaron los bloqueos completamente. Dentro de las estrategias preventivas impuestas por los gobiernos de diferentes países, las más comunes fueron: cierre de recintos educacionales, enseñanza a distancia, trabajo desde el hogar, cierre de tiendas y restaurantes, restricciones a las reuniones públicas y eventos sociales, imposición de toques de queda, limitación en la operación del transporte público y taxis, establecimiento de normativas para el distanciamiento social, cierre de fronteras y aeropuertos internacionales (Abdullah et al., 2020).

Múltiples estudios recientes caracterizan el impacto de la crisis sanitaria sobre el comportamiento de la movilidad de las personas, basándose en datos con diferentes niveles de agregación, obtenidos principalmente de la realización de encuestas, así como también al uso de teléfonos y aplicaciones móviles, sistemas automatizados de cobro de tarifas, entre otros.

En Abdullah et al. (2020) se examinan los cambios en el comportamiento de viaje a partir de la aplicación de una encuesta online realizada en varios países en el mes de mayo 2020. Realizan un análisis estadístico de los datos y estiman modelos de regresión logística multinomial. Se obtuvo que el propósito de viaje, la elección de modo, la distancia recorrida y la frecuencia de los viajes fueron significativamente diferentes antes y durante la pandemia por COVID-19. Se detectó un cambio importante en la demanda desde el transporte público hacia el transporte privado y modos no motorizados. Se observó también que el reemplazo del automóvil por modos no motorizados no fue significativo, y que el propósito de viaje “compras” tomó mayor relevancia, en desmedro del trabajo, estudio y otros. Adicionalmente, los resultados de la encuesta identifican a las variables género, propiedad del automóvil, situación laboral, distancia y propósito principal de viaje con una influencia significativa sobre la elección del modo durante la emergencia sanitaria, mientras que los factores ahorro de tiempo de viaje, comodidad y costo pierden relevancia. Además, las distancias de viajes tendieron a ser más cortas y los viajes menos frecuentes.

De Haas et al. (2020), por su parte, presenta un análisis descriptivo de los efectos actuales y futuros potenciales del virus sobre las actividades de las personas y su comportamiento de viaje, basado en la Encuesta de Panel de Movilidad en Países Bajos, la cual consiste en completar un diario de viajes para tres días consecutivos de marzo 2020 y un cuestionario sobre las características del hogar. Cabe señalar que las personas ya participaron anteriormente de la encuesta, por lo que es posible comparar con su comportamiento antes de la crisis sanitaria. Se obtuvo que el 80% de los viajeros redujo sus actividades al aire libre, con una disminución más fuerte para los adultos mayores. Por otro lado, el 44% de las personas incrementaron las horas trabajando desde el hogar.

A la vez, la cantidad de viajes y la distancia recorrida disminuyó en comparación al año 2019. Respecto a la percepción hacia los modos de transporte, la del automóvil mejora mientras que el transporte público pierde adeptos, alcanzando una reducción mayor al 90%. Las personas prefieren modos individuales y activos por sobre los compartidos.

Paralelamente, Bucsky (2020) analiza los cambios en la partición modal de Budapest, Hungría, debido a la incorporación de restricciones a la movilidad por la pandemia de COVID-19, a partir de diversas fuentes de información que le entregan los volúmenes diarios de tránsito durante el mes de marzo 2020 (estadísticas de transporte en carretera, uso de “Waze”, bases de datos de ubicación GPS de teléfonos, número de usuarios diarios en transporte público y de ciclistas). Determina que la reducción de demanda no fue idéntica en todos los modos, siendo el transporte público el que experimentó un mayor descenso (-80%), sustituyéndose por el transporte privado que aumentó desde un 43% a un 65%. Además, dicha disminución puede ser resultado de restricciones gubernamentales y/o del miedo a contagiarse.

De manera similar en Astroza et al. (2020) se estudian las diferencias en el número de viajes por propósito y modo, y se analiza el comportamiento de distintos segmentos de la población. Para ello, implementaron una encuesta online de movilidad realizada en marzo 2020 que compara una semana normal y con la semana inmediatamente después a la suspensión de las clases presenciales, en el inicio de la pandemia en Santiago de Chile. Realizaron también análisis descriptivos de los datos, en conjunto con la estimación de modelos probit y de regresión lineal. Los resultados muestran una reducción del 44% en la demanda global de viajes, siendo los modos metro, vehículo compartido y bus los más afectados. A su vez se obtiene una disminución en los viajes con propósito trabajo y estudio de un 43% y 73% respectivamente. Sobre el teletrabajo, se identifican diferentes efectos según el nivel de ingreso, donde un 75% de las personas con menores recursos debió salir a trabajar durante la emergencia sanitaria mientras que un 80% de los trabajadores con altos ingresos lo realizaron desde su hogar. Con ello, las personas pertenecientes a hogares de más recursos tuvieron una disminución mayor en el número de viajes. Por otro lado, se encontraron diferencias por género, siendo más probable que las mujeres trabajaran desde su hogar que los hombres, y por rango etario, donde las personas mayores mostraron una menor reducción en los viajes. Finalmente, factores como la propiedad de automóviles y pertenecer a grupos de alto riesgo por condiciones de salud no resultaron ser significativas.

Islind et al. (2020) utilizan diferentes fuentes de información entre enero y agosto 2020, incluidos los datos de movilidad de Apple Maps y aquellos proporcionados por OpenSky, para analizar los cambios en los patrones de movilidad en Europa durante la pandemia por COVID-19. Muestran que los cambios dependen de las estrategias que fueron adoptadas para combatir la crisis sanitaria. Del procesamiento de los datos se observa la reducción de la movilidad en marzo 2020, la cual se incrementa de forma gradual con distintas tasas, sin recuperar sus niveles normales en algunos países. En general, los habitantes europeos disminuyeron la caminata al encontrarse bajo confinamiento, mientras que el uso del automóvil se incrementó considerablemente.

Por su parte, Monderde-i-Bort et al. (2022) estudian la duración de los cambios observados en la elección de modo como consecuencia de la pandemia. Para ello, realiza una encuesta online en 10 países europeos, de la cual recopila información en dos periodos del año 2020, con la que es posible analizar el comportamiento antes, durante y después del confinamiento. Nuevamente, se obtiene que los modos automóvil, caminata y transporte público vieron reducido su uso en el momento más crítico de la emergencia sanitaria, no así la bicicleta. A su vez, finalizado el periodo de aislamiento la frecuencia de uso del transporte privado y caminata prácticamente retomaron los niveles iniciales, mientras que el transporte público aumentó su demanda, pero no logró alcanzar los valores previos.

Molloy et al. (2021) estima el impacto sobre la movilidad, tanto en el periodo de confinamiento como en el de relajación de restricciones, utilizando un panel de rastreo GPS derivado del uso de una aplicación móvil para habitantes de Suiza durante el año 2020. Esto se complementó con el desarrollo de encuestas online voluntarias. Se detectaron cambios significativos en la elección modal y una reducción de la distancia promedio diaria (-60%), siendo esta más fuerte para el transporte público (-90% al iniciar el confinamiento y -50% al finalizarlo). El modo bicicleta por su parte incrementó de manera notable el número de viajes diarios, principalmente al medio día, y la distancia recorrida, con lo que se infiere un uso más bien recreativo. Respecto al automóvil, se recuperaron los niveles observados en la situación inicial. Se identifican también variaciones sociodemográficas, donde residentes con mayor nivel educacional tuvieron una mayor disminución en los kilómetros, lo cual puede asociarse al teletrabajo.

Por otro lado, Bohnensteffen et al. (2021) realiza un análisis basado en datos de teléfonos móviles anonimizados y agregados para mostrar los cambios en la movilidad desde los inicios de la pandemia por COVID-19 en Alemania. Se detectan fluctuaciones en la movilidad desde marzo 2020, respecto al año 2019 previo a la crisis, dependientes de las medidas de restricción. Adicionalmente, se elabora un análisis del cambio diario en la movilidad por distrito, mediante un modelo de panel de efectos aleatorios, para tres periodos: marzo a junio 2020, julio a octubre 2020 y noviembre 2020 a febrero 2021. Se determina que las restricciones de movilidad afectan más a las grandes regiones densamente pobladas, y a las actividades de ocio por sobre las asociadas al trabajo. A la vez, se sugiere que el cambio en la movilidad se relaciona con la estructura económica del distrito, donde una mayor tasa de servicio se traduce en una mayor disminución de la movilidad. Respecto a las variables sociodemográficas, estas no resultan del todo significativas.

Finalmente, en Kellermann et al. (2022) se investigan los cambios en el comportamiento de la movilidad y efectos a largo plazo, inducidos por la emergencia sanitaria, mediante el análisis de los patrones de viaje de los residentes de Berlín, entre enero 2019 y octubre 2021. Específicamente, la data proviene del uso voluntario de dos aplicaciones para teléfonos inteligentes que registran los viajes y modos en función de un sistema de rastreo GPS. Con ella, se utilizan análisis de correlación y regresión lineal múltiple para estudiar el cambio en el comportamiento de movilidad con respecto a la elección de modos de transporte. Se consideró al promedio de viajes semanales y a la distancia promedio semanal como variables dependientes. Los resultados arrojan que las personas

prefirieron modos individuales, disminuyeron relativamente sus distancias y frecuencias de viaje en aproximadamente un 20% y 11% respectivamente, en comparación con el periodo de referencia previo a la pandemia. Paralelamente, el transporte público sufrió una reducción continua (-50%), mientras que la bicicleta evidenció un aumento de la frecuencia (+53%) y distancias de viaje (+117%) a largo plazo. Luego, el incremento sustancial en el uso de modos activos puede explicarse en la sustitución del transporte público.

En la tabla 2.3 se resume la literatura estudiada que analiza el impacto de la crisis sanitaria sobre la movilidad. Se agrupan por tipos de datos utilizados, metodología aplicada y principales hallazgos obtenidos. Es posible notar que las investigaciones muestran varios efectos comunes, cuya duración no es clara. En particular, los sistemas de transporte público se han visto considerablemente afectados por la pandemia global de COVID-19, independiente de las medidas sanitarias abordadas por las autoridades, sufriendo una reducción de la demanda debido, entre otras causas, a la percepción de riesgo de contagio (Tirachini y Cats, 2020). En el siguiente acápite se profundizará en este aspecto.

Tabla 2.3: Resumen estado del arte sobre el impacto del COVID-19 en la movilidad

Autor	Datos utilizados (ubicación)	Herramienta o método	Temas estudiados	Principales hallazgos
Abdullah et al. (2020)	Datos de encuesta online, mayo 2020 (más de 15 países)	Análisis descriptivos de los datos recopilados y regresión logística multinomial	Comportamiento de viaje y elección de modo	Aumento del uso del automóvil y modos activos
				Reducción en el uso del transporte público
				Incremento viajes con propósito compras
				Variables género y propiedad de automóvil significativas
				Disminución de la frecuencia de viaje y distancia recorrida
De Haas et al. (2020)	Datos de Encuesta de Panel de Movilidad, tres días consecutivos de marzo 2020 (Países Bajos)	Análisis descriptivos y comparativos de los datos recopilados en la encuesta online	Comportamiento de viaje	Reducción de las actividades al aire libre, más fuerte en adultos mayores
				Aumento de las horas trabajadas desde el hogar
				Disminución de la cantidad de viajes y la distancia recorrida
				Mejora en la percepción del automóvil
				Reducción en el uso del transporte público
				Preferencia por modos individuales y activos
Bucsky (2020)	Datos de volúmenes diarios de tránsito, marzo 2020 (Budapest, Hungría)	Análisis descriptivos y comparativos de bases de datos	Elección de modo	Reducción de demanda no fue idéntica en todos los modos, transporte público fue el más afectado
				Aumento en el uso del automóvil
Astroza et al. (2020)	Datos de encuesta, dos semanas de marzo 2020 (Santiago, Chile)	Análisis descriptivos de los datos recopilados, estimación de modelos probit y de regresión lineal	Comportamiento de viaje y elección de modo	Reducción de la demanda global de viajes
				Metro, vehículo compartido y bus tuvieron la mayor caída
				Disminución en los viajes con propósito trabajo y estudio
				Efectos en el teletrabajo dependen del nivel de ingreso
				Mayor probabilidad de que las mujeres trabajaran desde su hogar, respecto a los hombres
				Menor reducción de los viajes en personas mayores

Autor	Datos utilizados (ubicación)	Herramienta o método	Temas estudiados	Principales hallazgos
Islind et al. (2020)	Datos de movilidad de Apple Maps, Enero 2020 – Agosto 2020 (Europa)	Análisis descriptivos y comparativos de las bases de datos en línea	Patrones de movilidad	Cambios dependen de las estrategias adoptadas
				Reducción de la movilidad en los inicios de la pandemia
				Incremento gradual de la movilidad, sin recuperar los niveles previos en algunos países
				Disminución de la caminata bajo confinamiento
				Aumento del uso del automóvil
Monterde-i-Bort et al. (2022)	Datos de encuesta online, dos periodos del año 2020 (Europa)	Análisis descriptivos de las bases de datos en línea y aplicación de pruebas estadísticas	Elección de modo	Modos automóvil, caminata y transporte público redujeron su uso en el momento más crítico de la emergencia sanitaria
				Modo bicicleta no se vio afectado
				Frecuencia de uso del transporte privado y caminata se recuperaron post confinamiento
				Transporte público no logró recuperar la demanda previa
Molloy et al. (2021)	Registro de aplicación para teléfonos móviles y panel de rastreo GPS, 2020 (Suiza)	Análisis descriptivo estadístico de los datos recopilados en aplicaciones y encuestas en línea	Patrones de movilidad y elección de modo	Disminución de la distancia promedio diaria
				Reducción en el uso del transporte público
				Aumento número de viajes y distancia de bicicleta
				Recuperación total del automóvil
				Residentes con mayor nivel educacional tuvieron una mayor disminución de la distancia
Bohnensteffen et al. (2021)	Registros de teléfonos móviles, Marzo 2020 - Febrero 2021 (Alemania)	Estimación de modelo de panel de efectos aleatorios	Patrones de movilidad	Cambios en la movilidad dependen de las restricciones
				Restricciones de movilidad afectan más a las grandes regiones densamente pobladas
				Restricciones afectan más a las actividades de ocio
Kellermann et al. (2022)	Registro de aplicación en teléfonos y sistema de rastreo GPS, Enero 2019 – Octubre 2021 (Berlín, Alemania)	Análisis de correlación y regresión lineal múltiple	Comportamiento de viaje, elección de modo y patrones de movilidad	Aumento en el uso de modos individuales y activos
				Disminución de la distancia recorrida
				Disminución de la frecuencia de viaje
				Reducción en el uso del transporte público

Fuente: Elaboración Propia

2.4. COVID-19 y transporte público

Las investigaciones realizadas en los últimos años muestran que los sistemas de transporte público fueron uno de los más afectados con la llegada de la pandemia por COVID-19. Las restricciones impuestas, el cierre de sectores económico, así como también la opción de abstenerse a viajar para reducir la exposición con otras personas y la percepción de riesgo de contagio, explica en gran medida la disminución en el número de viajes y los cambios en las elecciones (Tirachini y Cats, 2020).

Este impacto se ha abordado desde diferentes perspectivas, incluyendo el análisis de las medidas tomadas por las autoridades para reducir las probabilidades de contagios, estadísticas descriptivas de la demanda y comprensión de las causas de la caída en el uso, estudio de los cambios en los patrones de viajes de los usuarios, entre otros (Basnak et al., 2022).

Respecto a la primera área mencionada, Tirachini y Cats (2020) realizan una completa descripción de la literatura existente a junio 2020 sobre las implicancias de la emergencia sanitaria en el transporte público. En efecto, las normativas adoptadas en los países variaron desde la recomendación de evitar su uso (Reino Unido, Países Bajos, Estados Unidos), controles de distanciamiento físico y reducciones de capacidad (Australia), uso obligatorio de mascarillas faciales, aplicación de medidas de higiene como desinfección constante y ventilación, hasta la no imposición de restricciones estrictas (China, Taiwán, Corea del Sur).

En el caso de América Latina, las normativas sobre el transporte público fueron similares; en algunos países se decidió limitar totalmente su uso (República Dominicana), mientras que en otros se incorporaron restricciones en la ocupación (Colombia, Argentina). No obstante, en ninguno se han retomado por completo los niveles de demanda existentes previo a la pandemia (Pardo et al., 2021).

Paralelamente, De Vos (2020) estudia los efectos potenciales del distanciamiento social en el comportamiento de viaje y describe las implicancias para la salud. Sugiere que el distanciamiento físico reducirá la demanda de viajes y podría influir en la elección del modo, dado que las personas tenderán a evitar el transporte público por la dificultad de evitar el contacto con otros pasajeros. A la vez, aquellos que tienen acceso a un automóvil incrementarán su uso, mientras que los pasajeros que no tienen más alternativas tratarán de sortear buses y trenes llenos viajando en horarios fuera de punta. Luego, la menor participación en actividades afectará negativamente el bienestar subjetivo.

Por su parte, Pardo et al. (2021) efectúan una revisión de la transmisión del virus en el transporte público para América Latina, enfocándose en medidas que reducen el riesgo de propagación. Identifican a la distancia social, buena ventilación, duración del viaje corta, limpieza frecuente de superficies, comportamiento de los usuarios (correcto uso de mascarilla, protección ocular y silencio) y sugerencias de ocupación máxima, por tipo de vehículo y nivel de transmisión, como factores que permiten reducir la probabilidad de contagio.

Con respecto a los estudios que describen las variaciones de la demanda en transporte público durante la crisis sanitaria, analizan el impacto de su caída y las posibles causas, junto a los cambios en los patrones de viajes, en general se basan en los resultados entregados por la aplicación de encuestas, o bien en la estimación de modelos a partir de datos pasivos.

En efecto, en Basnak et al. (2022) se analizan los cambios en las preferencias de modo desde la llegada del COVID-19, debido al impacto de las aglomeraciones y el uso de mascarilla en el transporte público, mediante la aplicación de una encuesta online de preferencias declaradas en Santiago de Chile. Se estimaron modelos de elección de modo, los cuales determinan penalizaciones por hacinamiento para antes y durante la crisis sanitaria, que dependen del tipo de pasajero y del uso de mascarilla. Se encontraron diferencias por género, edad y nivel de ingreso, donde las mujeres son más susceptibles que los hombres al uso de mascarillas en el transporte público, mientras que personas jóvenes y con menores ingresos son menos sensibles al hacinamiento. Otros factores relevantes para explicar la elección del modo son la desinfección de vehículos, percepción de riesgo para la salud, limpieza, seguridad y comodidad.

Por otra parte, Gramsch et al. (2022) estudia el efecto de los confinamientos dinámicos en la demanda de transporte público, utilizando datos de viajes diarios en los años 2019 y 2020, a nivel comunal, mediante el uso de tarjetas inteligentes en el sistema de Santiago, Chile. Para ello, realizan un análisis de regresión, considerando como variable dependiente a la razón entre el número de viajes en transporte público sobre la población total de la comuna en un día respectivo, junto con variables explicativas sociodemográficas y asociadas a la eficacia de los confinamientos. Los resultados determinan que los bloqueos dinámicos tienen una efectividad a corto plazo disminuyendo la cantidad de pasajeros, con un impacto mayor en los buses, posiblemente por la evasión al pago de la tarifa. Además, detectan que los confinamientos tienen un mayor efecto en la reducción de la demanda en áreas con más alta proporción de adultos mayores e ingresos.

Liu et al. (2020) utiliza datos entre febrero y mayo 2020 del número de pasajeros diarios, provenientes de la aplicación en teléfonos móviles “Transit”, para analizar los impactos del COVID-19 en sistemas de transporte público de Estados Unidos. El procedimiento requiere ajustar curvas logísticas que describan la reducción de la demanda diaria. Posteriormente, se estiman modelos de regresión de mínimos cuadrados ordinarios y se determinan factores socioeconómicos y demográficos significativos en explicar la disminución de los pasajeros diarios durante la crisis sanitaria.

Los resultados indican que mayores reducciones de la demanda se relacionan con un mayor porcentaje de personas con ocupaciones no físicas, es decir, con la posibilidad de trabajar desde su hogar. También se obtiene que las variables razón de la población mayor de 45 años y proporción de mujeres se asocian con niveles más altos de uso del transporte público. Señalan que los descensos en la demanda son desiguales entre comunidades y grupos sociales (Liu et al., 2020).

Por otro lado, Gkiotsalitis y Cats (2021) realizan una revisión de la literatura sobre los impactos del COVID-19 en el transporte público. Identifican una caída en el número de pasajeros durante el periodo de confinamiento que fluctúa entre el 60% y 90% para distintas ciudades estudiadas alrededor del mundo, acompañada por lo general de una disminución en el número de servicios, frecuencia y estaciones operativas. Si bien al levantar las restricciones las preocupaciones sobre el uso del transporte público se han reducido, los pasajeros siguen mostrando cierto recelo. Luego, la percepción de riesgo que se genera por el temor al contagio puede afectar tanto las decisiones de viaje inmediatas como las de largo plazo.

A su vez, Wilburý et al. (2020) proporciona un análisis espaciotemporal y entre grupos socioeconómicos de la disminución en el número de pasajeros de transporte público debido a la pandemia por COVID-19. Se consideran para ello los datos de subidas entre enero 2019 y julio 2020 en los sistemas de buses de Nashville y Chattanooga, Tennessee, Estado Unidos. Encuentran una reducción de los usuarios de aproximadamente un 65% en comparación con la situación de referencia de 2019, antes de comenzar una recuperación moderada, estabilizándose en un 45%. Las mayores caídas se perciben en los horarios punta mañana y punta tarde, lo que indica que las restricciones impuestas tienen efecto. Se detectan diferencias significativas entre distritos censales en la disminución del número de pasajeros, donde las áreas de mayores ingresos presentan una reducción mayor (-77%) que las áreas con ingresos más bajos (-58%).

De forma similar, Qi et al. (2021) estudia el impacto de la crisis sanitaria sobre la cantidad de pasajeros del transporte público (bus y tren ligero) en veinte áreas metropolitanas de Estados Unidos. Para ello, recopilaron datos de usuarios de los sistemas en el periodo comprendido desde febrero 2019 hasta enero 2021. Estos se complementan con información sociodemográfica y datos de casos y muertes de COVID-19 en el periodo analizado. Posteriormente, desarrollan modelos de datos de panel de efectos aleatorios y fijos, junto con modelos de regresión tradicionales, para estimar el impacto de la pandemia y otros factores socioeconómicos, considerando como variable dependiente a la tasa de reducción mensual del número de viajeros año a año. Construyen además una variable explicativa que mide cuantitativamente el nivel de miedo frente al uso del transporte público. Los resultados muestran que las áreas con mayor nivel de ingreso, mayor nivel educacional y con una tasa de empleo más alta tienen mayores caídas en el número de usuarios durante la pandemia de COVID-19. Por otro lado, el indicador de “miedo” obtiene el efecto contrario, donde un aumento de este favorece la reducción de la cantidad de pasajeros.

A pesar de aplicar diferentes metodologías, se obtienen las mismas conclusiones en Ahangari et al. (2020), Hu y Chen (2021) y Brough et al. (2021): un incremento en la tasa de desempleo, ingreso promedio, capacidad de trabajar de manera remota, posesión de vehículo particular o en el nivel educacional provocan una mayor reducción en el número de pasajeros en transporte público. Adicionalmente, los grupos con bajos ingresos y menores grados educacionales disminuyen a una menor intensidad sus viajes en transporte público debido a la pandemia, evidenciando impactos dispares sobre la movilidad en función de la situación socioeconómica.

Wang et al. (2022) por su parte mide la resiliencia del comportamiento de viaje a partir de indicadores de movilidad, construidos con los registros de viajes pagados con tarjetas inteligentes o plataformas de pago virtuales, entre noviembre 2019 y septiembre 2020 en el sistema de metro de Kunming, China. Identifican a los viajeros frecuentes antes y durante la pandemia, obteniendo una muestra de 16.403 sujetos y los clasifican en cuatro grupos: viajeros, ancianos, estudiantes y otros. Dentro de los indicadores considerados, los cuales se calculan semanalmente, se encuentra el número de viajes, días de viaje, distancia total de viaje, duración del viaje y el número de estaciones visitadas en el periodo de estudio. Luego, les dan seguimiento a los usuarios y estudian si retoman su nivel de movilidad.

Los resultados arrojan una lenta recuperación en el uso del transporte público, la cual se describe en tres fases; una reducción drástica de acuerdo a la disminución significativa de los indicadores de movilidad, un rápido crecimiento donde la tasa de recuperación de los indicadores se restauró gradualmente a los niveles prepandemia, y su estabilización. Se detectan diferentes tiempos de recuperación entre los grupos analizados y una reducción de la variabilidad de propósitos de viaje. Además, los viajeros retoman la frecuencia y duración de los viajes, mientras que los adultos mayores disminuyen la frecuencia, pero mantienen la duración del viaje (Wang et al., 2022).

Finalmente, sobre los principales cambios en los patrones de movilidad de los usuarios de transporte público en respuesta a la exposición del virus, Tirachini y Cats (2020) los agrupan en: alteración de la ruta de viaje por una menos hacinada, modificación de la hora de salida para evitar horarios punta, preferencia por modos de transporte privado y no compartidos, cambios en el destino de viaje por uno menos concurrido o incluso, abstinencia de viajar. Señalan que la capacidad de adaptarse dependerá de las preferencias personales, las características socioeconómicas del hogar y su composición, la flexibilidad laboral, la posibilidad de efectuar teletrabajo y la disponibilidad de automóviles.

En la tabla 2.4 se consolida la literatura revisada, la cual se agrupa por tipos de datos, metodología aplicada, variables consideradas y principales hallazgos obtenidos. Como se puede observar, el estado del arte se concentra en analizar y explicar el cambio modal desde el transporte público hacia otros modos de transporte, así como también las modificaciones en el comportamiento de los usuarios durante la pandemia por COVID-19. Pocas investigaciones se han enfocado en estudiar sistemáticamente la recuperación de su movilidad, identificar variables que la potencian y cuantificar su impacto. El presente trabajo buscará aportar en esta área mediante la estimación de modelos estadísticos, para diferentes cortes temporales, que relacionen la cantidad de pasajeros del transporte público con variables socioeconómicas y de accesibilidad, entre otros factores, lo cual será descrito en los capítulos que siguen.

Tabla 2.4: Resumen estado del arte sobre el impacto del COVID-19 en el transporte público

Autor	Datos utilizados (ubicación)	Herramienta o método	Temas estudiados	Principales hallazgos
Tirachini y Cats (2020)	Estado del arte	Revisión bibliográfica	Transmisión del virus COVID-19 en transporte público	Diferentes recomendaciones alrededor del mundo respecto al transporte público: evitar uso, distanciamiento físico, reducir la capacidad, uso obligatorio de mascarillas, desinfección y ventilación, entre otras.
De Vos (2020)	Estado del arte	Revisión bibliográfica	Comportamiento de viaje y distanciamiento físico	Distanciamiento físico reducirá la demanda de viajes
				Usuarios evitarán el transporte público para reducir contacto
				Aumentará el uso del automóvil
				Ante buses y trenes llenos, los usuarios optarán por viajar en horarios fuera de punta
Pardo et al. (2021)	Estado del arte (América Latina)	Revisión bibliográfica	Transmisión del virus COVID-19 en transporte público	Medidas que reducen el riesgo de propagación: distancia social, ventilación, corta duración del viaje, limpieza frecuente, uso de mascarilla y ocupación máxima en vehículos
Basnak et al. (2022)	Datos de encuesta online de preferencias declaradas, agosto, septiembre y octubre 2020 (Santiago, Chile)	Estimación de modelos multinomial, anidado y mixto de logit	Aglomeraciones y uso de mascarilla en transporte público durante la pandemia por COVID-19	Diferentes penalizaciones por hacinamiento, para antes y después de la pandemia
				Diferentes penalizaciones por género, edad e ingreso
				Mujeres más sensibles al uso de mascarilla
				Jóvenes y personas con menor ingreso menos sensible al hacinamiento Otros factores que explican la elección de modo: desinfección, percepción de riesgo, seguridad y comodidad
Gramsch et al. (2022)	Datos de volúmenes diarios de tránsito, 2019 y 2020 (Santiago, Chile)	Análisis de regresión múltiple lineal	Confinamientos dinámicos	Efectividad a corto plazo de los bloqueos dinámicos
				Mayor impacto de los bloqueos dinámicos en buses
				En áreas con mayor proporción de adultos mayores e ingresos, el confinamiento tiene un efecto más fuerte sobre la reducción de la demanda

Autor	Datos utilizados (ubicación)	Herramienta o método	Temas estudiados	Principales hallazgos
Liu et al. (2020)	Datos de volúmenes diarios de la aplicación Transit, Febrero 2020 – Mayo 2020 (Estados Unidos)	Análisis de regresión lineal múltiple	Cambios en la demanda en transporte público debido al COVID-19	<p>Mayor reducción de la demanda se relacionan con un mayor porcentaje de personas con ocupaciones no físicas</p> <p>Variables población mayor de 45 años y proporción de mujeres se asocian con mayor uso del transporte público</p> <p>Descensos en la demanda desiguales entre grupos sociales</p>
Gkiotsalitis y Cats (2021)	Estado del arte	Revisión bibliográfica	Cambios en la demanda en transporte público debido al COVID-19	<p>Caída en el número de pasajeros en periodo de confinamiento entre 60%-90%</p> <p>Reducción en el número de servicios, frecuencia y estaciones operativas durante el periodo de confinamiento</p> <p>Preocupación sobre el transporte público se reduce al levantar restricciones, pero no se elimina del todo</p>
Wilburÿ et al. (2020)	Datos de subidas, enero 2019 - julio 2020 (Tennessee, Estado Unidos)	Análisis espacio temporal de bases de datos	Cambios en la demanda en transporte público debido al COVID-19	<p>Reducción de los usuarios de 65% en comparación con periodo pre pandemia</p> <p>Recuperación se estabiliza en un 45% menos de usuarios en comparación con periodo pre pandemia</p> <p>Mayores caídas en horarios punta mañana y punta tarde</p> <p>Áreas de mayores ingresos presentan una reducción mayor de la demanda que las áreas con ingresos más bajos</p>
Qi et al. (2021)	Datos de volúmenes diarios de tránsito, febrero 2019 – enero 2021 (Estados Unidos)	Análisis de modelos de datos de panel de efectos aleatorios y fijos, y modelos de regresión lineal	Cambios en la demanda en transporte público debido al COVID-19	<p>Las áreas con mayor nivel de ingreso, nivel educacional y tasa de empleo tienen mayores caídas en el número de usuarios</p> <p>Aumento en el indicador de “miedo” favorece la reducción de la cantidad de pasajeros</p>
Ahangari et al. (2020)	Datos de volúmenes de tránsito nacionales, 2019 – 2020 (Estados Unidos)	Análisis de bases de datos y de regresión	Cambios en la demanda en transporte público debido al COVID-19	<p>Variables ingresos, educación (porcentaje de personas con título en educación superior), residentes nacidos en el extranjero y tasa de desempleo afectan directamente a la reducción del número de pasajeros</p> <p>Variable personas sin vehículo tiene un efecto inverso en la reducción del número de pasajeros</p>

Autor	Datos utilizados (ubicación)	Herramienta o método	Temas estudiados	Principales hallazgos
Hu y Chen (2021)	Datos de volúmenes de tránsito diarios, Enero 2001 – Mayo 2020 (Chicago, Estados Unidos)	Análisis de regresión de mínimos cuadrados parciales	Cambios en la demanda en transporte público debido al COVID-19	Se obtuvo una caída promedio del 72% en el número de pasajeros
				Disminución fue mayor en áreas comerciales, con porcentajes más altos de personas blancas, educadas y de altos ingresos
				Áreas con más empleos en sectores de comercio, transporte y servicios públicos tuvieron caídas menores
Brough et al. (2021)	Datos de volúmenes de tránsito y encuesta de preferencias, Enero 2001 – Mayo 2020 (Washington, Estados Unidos)	Análisis de regresión múltiple lineal	Comportamiento de viaje	Los viajes disminuyeron menos en personas menos educadas y de bajos ingresos
				Al levantar las restricciones y aumentar los viajes, la brecha socioeconómica se mantuvo estable
				Importancia de la capacidad de trabajar de forma remota para explicar las disparidades entre grupos
Wang et al. (2022)	Datos de volúmenes de tránsito, noviembre 2019 - septiembre 2020 (Kunming, China)	Análisis de indicadores de movilidad	Comportamiento de viaje	Lenta recuperación en el uso del transporte público
				Diferentes tiempos de recuperación entre los grupos analizados
				Reducción de la variabilidad de propósitos de viaje
				Viajeros retoman la frecuencia y duración de los viajes
				Adultos mayores disminuyen la frecuencia pero mantienen la duración del viaje

Fuente: Elaboración Propia

2.5. Modelos econométricos

En el siguiente acápite se describen los modelos econométricos que se implementarán en esta tesis para determinar la relación entre la no recuperación total de la movilidad de los usuarios del transporte público en Santiago de Chile, debido a la pandemia global por COVID-19, y un conjunto de variables explicativas a considerar. Entre los métodos aplicados se encuentran los modelos de regresión lineal múltiple y de regresión espacial.

2.5.1. Regresión lineal múltiple

Los modelos de regresión lineal múltiple, cuya forma funcional matricial se muestra en la ecuación 2.1, permiten estudiar cómo los cambios en el conjunto de variables predictoras, descritas y caracterizadas en el capítulo 5, afectan a los valores de la variable dependiente observada

$$Y = X\beta + \varepsilon \quad (2.1)$$

En ella, Y es un vector de $(N \times 1)$ donde se encuentran las N observaciones de la variable explicada, X es una matriz de forma conocida con dimensión $(N \times Q)$ que contiene las observaciones de las variables explicativas, β es un vector de $(Q \times 1)$ parámetros de regresión y ε es un vector de $(N \times 1)$ términos de error. Paralelamente, el modelo de regresión lineal múltiple en su versión muestral se observa en la ecuación 2.2 (Hastie et al., 2017).

$$y_i = \beta_0 + \sum_{q=1}^Q x_{iq} \beta_q + \varepsilon_i, i=1, \dots, N \quad (2.2)$$

En efecto, y_i representa a la observación i de la variable dependiente, mientras que x_{iq} es la observación i de una de las q variables explicativas, con $q=1, \dots, Q$. A su vez, β_0 corresponde a la constante del modelo y β_q son los coeficientes o parámetros de regresión estimados para cada variable explicativa, los cuales miden la influencia por sí sola de una variable independiente sobre la variable dependiente. Por último, ε_i corresponde al término de error o residuo de la observación, que se debe a variables no controladas y a la variabilidad propia de la muestra.

Con respecto a los parámetros de regresión, el método de estimación más utilizado es el de mínimos cuadrados ordinarios, en el cual se escogen los coeficientes β que minimicen la suma de los residuos al cuadrado (RSS). La función de error cuadrático a minimizar está dada por la expresión 2.3, donde MSE corresponde al error cuadrático medio (Hastie et al., 2017).

$$RSS(\beta) = \sum_{i=1}^N \varepsilon_i^2 = \sum_{i=1}^N \left(y_i - \beta_0 - \sum_{q=1}^Q x_{iq} \beta_q \right)^2 = N \cdot MSE(\beta) \quad (2.3)$$

Cabe señalar que, podría resultar útil efectuar comparaciones del peso de los coeficientes β obtenidos, para valorar la importancia relativa de cada variable explicativa respecto a la variable estudiada. Para ello, se utilizan los coeficientes de regresión estandarizados, correspondientes a los coeficientes de regresión β , normalizados por la relación entre la desviación estándar del regresor y la desviación estándar de la variable dependiente. Esto vuelve irrelevante las escalas de los regresores y coloca a las variables explicativas en igualdad de condiciones. Para su cálculo, se resta la media y se divide por la desviación estándar de cada observación, es decir, se obtiene su puntuación Z (Wooldridge, 2009). Con esto, las variables son estandarizadas para que tengan una media de 0 y una desviación estándar de 1

Por otro lado, para aplicar adecuadamente la técnica de mínimos cuadrados ordinarios se debe verificar el cumplimiento de los supuestos que se describen a continuación (Wooldridge, 2009; Guevara, 2022).

- *Linealidad:* La relación entre la variable explicada y las variables predictoras debe ser lineal. Esto no impide que se pueden crear transformaciones no-lineales de las variables antes de ser usadas en el modelo.
- *Exogeneidad de los errores.* La esperanza condicional de los errores, dada las variables explicativas debe ser igual a cero. Esto es indispensable para obtener estimadores insesgados de los coeficientes del modelo.
- *No colinealidad:* Las variables explicativas no deben estar perfectamente correlacionadas entre ellas. Esto es indispensable para calcular el estimador de mínimos cuadrados pues el proceso implica invertir la matriz de variables explicativas.
- *Homocedasticidad:* Los errores deben tener varianza constante, es decir, $\text{Var}(\varepsilon_i) = \sigma^2$ para todo i .
- *No autocorrelación:* Los errores no deben estar correlacionados entre observaciones. Si se cumple homocedasticidad y no autocorrelación, los estimadores serán los de menor varianza entre todos los estimadores insesgados, gracias al teorema de Gauss-Markov. Estos dos supuestos son también necesarios para estimar los errores estándar y hacer inferencia.
- *Normalidad:* Los errores del modelo deben seguir una distribución normal. Si se agrega el supuesto de normalidad, el estimador de mínimos cuadrados ordinarios será igual al estimador máximo verosímil, alcanzando así el límite de Cramer Rao de mínima varianza.

Esto permitirá utilizar los modelos de regresión lineal múltiple para comprender la relación existente entre la variable explicada y las respectivas variables explicativas. Si alguna de las condiciones no se alcanza, entonces las conclusiones obtenidas del ajuste del modelo podrían no

ser confiables en los sentidos que se indican, debiendo aplicarse, en la medida de lo posible, métodos para corregirlo.

Un supuesto que usualmente es violado en modelos de carácter espacial es la no-auto correlación, debido a que se espera que los errores de las zonas más cercanas estén más correlacionados entre ellos que con el del resto de las zonas. Este problema, de ocurrir por sí solo, puede comprometer la eficiencia de los estimadores y dificultar el cálculo de los errores estándar de los estimadores. Si, además de la autocorrelación de errores, ocurre que variables dependientes de zonas aledañas explican el modelo de una zona (como en el modelo autoregresivo mostrado en la ecuación 2.4), se puede comprometer también la exogeneidad de los errores, con el consiguiente impacto en el sesgo de los estimadores. En la siguiente sección se describen modelos para abordar estas posibles limitaciones.

2.5.2. Regresión espacial

En muestras de datos espaciales transversales, las cuales representan observaciones asociadas a puntos, regiones, estados o distritos censales, entre otros, se identifica de manera regular la presencia de dependencia espacial. Esta refleja la situación en la que los valores observados en un lugar o región, dígame la observación i , dependen de los valores de las observaciones vecinas en lugares cercanos (LeSage y Kelley, 2009).

La literatura sobre econometría espacial distingue diversos tipos de modelos econométricos espaciales. La diferencia entre ellos es el tipo y número de retardos espaciales incluidos, ya que la dependencia puede encontrarse en variables explicativas, en la variable explicada, en los residuos (términos de error) o bien como una combinación de las opciones anteriores.

En primer lugar, cuando la correlación espacial se encuentra en la variable dependiente Y , los modelos se denominan de retardo espacial. En este caso, las observaciones de la variable explicada en el área i dependen de las observaciones en áreas vecinas (Borrego, 2018). En la ecuación 2.4 se muestra la forma funcional del modelo de retardo espacial o también conocido como modelo autorregresivo espacial de primer orden (SAR).

$$y_i = \rho \sum_{j=1}^N W_{ij}y_j + \beta_0 + \sum_{q=1}^Q x_{iq}\beta_q + \varepsilon_i, i=1, \dots, N \quad (2.4)$$

Se considera que el término de error ε_i es independiente e idénticamente distribuido. W_{ij} es el elemento (i,j) de la matriz de pesos espaciales W , de dimensión $(N \times N)$. Ella simboliza la disposición espacial de las unidades transversales en la muestra y suele estandarizarse por filas, con el objetivo de que los valores individuales W_{ij} estén proporcionalmente representados. Los elementos diagonales de la matriz son cero, mientras que los elementos no diagonales W_{ij} ($i \neq j$) muestran la relación entre las áreas i y j (Borrego, 2018).

Existen diversas formas de representar las relaciones espaciales W_{ij} . Es posible definir vecinos contiguos de primer orden a las áreas que tienen un límite común. Luego W_{ij} será igual a 1 si el área j comparte un límite con el área i . Otra alternativa es establecer que dos áreas i y j son vecinas, y por ende W_{ij} es igual a 1, si la distancia d_{ij} entre sus centroides es menor que un valor crítico dado. Adicionalmente, se ha utilizado a la distancia inversa para determinar la relación existente, tal que los pesos W_{ij} son iguales al inverso de la longitud que separa a los centroides de las áreas i y j (Borrego, 2018).

Por otro lado, el parámetro ρ a estimar determina el nivel de relación autorregresiva espacial entre y_i y $\sum_{j=1}^N W_{ij}y_j$, donde este último se conoce como la variable dependiente espacialmente retardada. Luego, si ρ es igual a cero entonces no hay dependencia espacial en el vector de observaciones transversales Y (LeSage y Kelley, 2009).

En lo que respecta a los modelos de error espacial (SEM), su especificación se basa en un proceso autorregresivo espacial de primer orden en el término de error, donde el efecto de dependencia en la variable endógena y_i es explicado no solo por las variables independientes, sino que también por otras que se ausentan. En concreto, la dependencia puede surgir de factores o variables latentes no observables que están correlacionadas espacialmente, siguiendo la forma funcional de las expresiones 2.5 y 2.6 (Borrego, 2018).

$$y_i = \beta_0 + \sum_{q=1}^Q x_{iq} \beta_q + u_i \quad (2.5)$$

$$u_i = \lambda \sum_{j=1}^N W_{ij} u_j + \varepsilon_i, \quad i=1, \dots, N \quad (2.6)$$

Donde λ es el parámetro autorregresivo espacial, u_i es la perturbación aleatoria que sigue un proceso autorregresivo de orden 1, ε_i el término de error aleatorio y W_{ij} un elemento de la matriz espacial W . Como se indicó anteriormente, en el caso de tener, simultáneamente, un modelo SAR y SEM, se violará el supuesto de exogeneidad de los errores, comprometiendo el insesgamiento de los estimadores. Dicho problema se puede resolver utilizando métodos de variables instrumentales.

Por otro lado, los modelos espacialmente retardados en X (SLX) o también conocidos por modelos regresivos cruzados de regresión espacial, representan como el valor de la variable dependiente y_i en el área i se ve afectada por variables explicativas de áreas cercanas. Es decir, el efecto de dependencia espacial se observa en forma de retardo espacial en una o varias variables independientes del modelo, tal como se expresa a continuación (Borrego, 2018).

$$y_i = \beta_0 + \sum_{q=1}^Q x_{iq} \beta_q + \sum_{j=1}^N \sum_{r=1}^R W_{ij} x_{jr} \theta_r + \varepsilon_i, i=1, \dots, N \quad (2.7)$$

Donde x_{ir} corresponde al valor en el área i de la variable explicativa r espacialmente retardada, que puede o no estar incluida dentro de las q variables del modelo. W_{ij} es un elemento de la matriz espacial W . A su vez, θ_r es un vector de $(R \times 1)$ que contiene los coeficientes adicionales estimados, tal que $\theta_r W$ medirá el desbordamiento de las R variables exógenas espacialmente retardadas.

Es importante notar que en estos modelos, los cambios en una sola observación (región) asociados con cualquier variable explicativa dada afectarán a la región misma (impacto directo) y potencialmente afectarán a las demás regiones (impacto indirecto, spillover). En concreto, los efectos de desbordamiento espacial o “spillovers” de este modelo coinciden con las estimaciones de los parámetros θ de las variables WX , y los efectos directos con las estimaciones de los parámetros β de las variables X (LeSage y Kelley, 2009).

Por último, sobre las medidas para identificar la autocorrelación espacial se destaca el estadístico I de Morán como uno de los más utilizados, el cual se presenta en la expresión 2.8. En ella, N corresponde al número de observaciones, W_{ij} es un elemento de la matriz espacial W , x_i y x_j son valores observados de las áreas i y j , y \bar{x} es la media de los valores observados (Borrego, 2018).

$$I = \frac{N}{\sum_i \sum_j W_{ij}} \cdot \frac{\sum_i \sum_j W_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_i (x_i - \bar{x})^2} \quad (2.8)$$

La I de Morán fluctúa entre -1 (dispersión perfecta, autocorrelación espacial negativa) y 1 (correlación perfecta, autocorrelación espacial positiva), donde valores absolutos más altos representan una correlación espacial más fuerte. Si el estadístico equivale a 0 entonces no se identifica la presencia de autocorrelación espacial, es decir, indica un patrón espacial aleatorio.

A su vez, bajo condiciones de normalidad y un número adecuado de áreas, es factible aplicar una prueba o test I de Morán a los residuos de un modelo estimado, permitiendo analizar la autocorrelación espacial de los datos mediante contrastes de hipótesis. En efecto, se transforma el estadístico I de Morán a una puntuación Z de acuerdo con lo indicado en la ecuación 2.9, donde $E(I)$ corresponde al valor esperado del estadístico y $\text{Var}(I)$ a su varianza. Luego, se obtiene el p -valor e interpretan los resultados dentro del contexto de la hipótesis nula (Borrego, 2018). Con ello, valores de Z superiores a $1,96$ o menores a $-1,96$ indican la presencia de autocorrelación espacial significativa con un nivel de confianza del 95%.

$$Z(I) = \frac{I - E(I)}{\sqrt{\text{Var}(I)}} \sim N(0,1) \quad (2.9)$$

Capítulo 3: Metodología y Datos

El presente capítulo tiene por finalidad mostrar la metodología abordada en el trabajo, la que permitirá estudiar los cambios en los patrones de movilidad del transporte público de la ciudad de Santiago de Chile, debido a la pandemia por COVID-19. A su vez, se recopilan, generan y describen los datos usados en la investigación.

Posteriormente, se caracteriza el sistema bajo el cual se encuentra inmerso el transporte público en el caso estudiado, que corresponde a la fuente de los datos que se utilizarán. A su vez, se entregan antecedentes del desarrollo de la crisis sanitaria y el impacto que esta tuvo en la ciudad.

Por último, se muestran los principales atributos contenidos en las bases de datos pasivos generados por la operación del transporte público y se describen los seis cortes temporales a analizar, correspondientes a seis semanas de transacciones con tarjetas inteligentes, representativas de diferentes escenarios de la pandemia.

3.1. Descripción general de la metodología

Para alcanzar el objetivo propuesto en este trabajo de investigación, se aplicará una metodología que consta de dos etapas, cada una con sus respectivas fases, las cuales se resumen en las figuras 3.1 y 3.2. Esta se inspira en el proceso Cross Industry Standard Process for Data Mining (CRISP-DM) (Chapman et al., 2000),

La primera de las etapas consiste en realizar un análisis agregado de los patrones de movilidad de los usuarios del transporte público, basado en los datos reales de transacciones realizadas en diferentes cortes temporales de los años 2020 y 2021. Para ello se siguen los pasos que se describen a continuación.

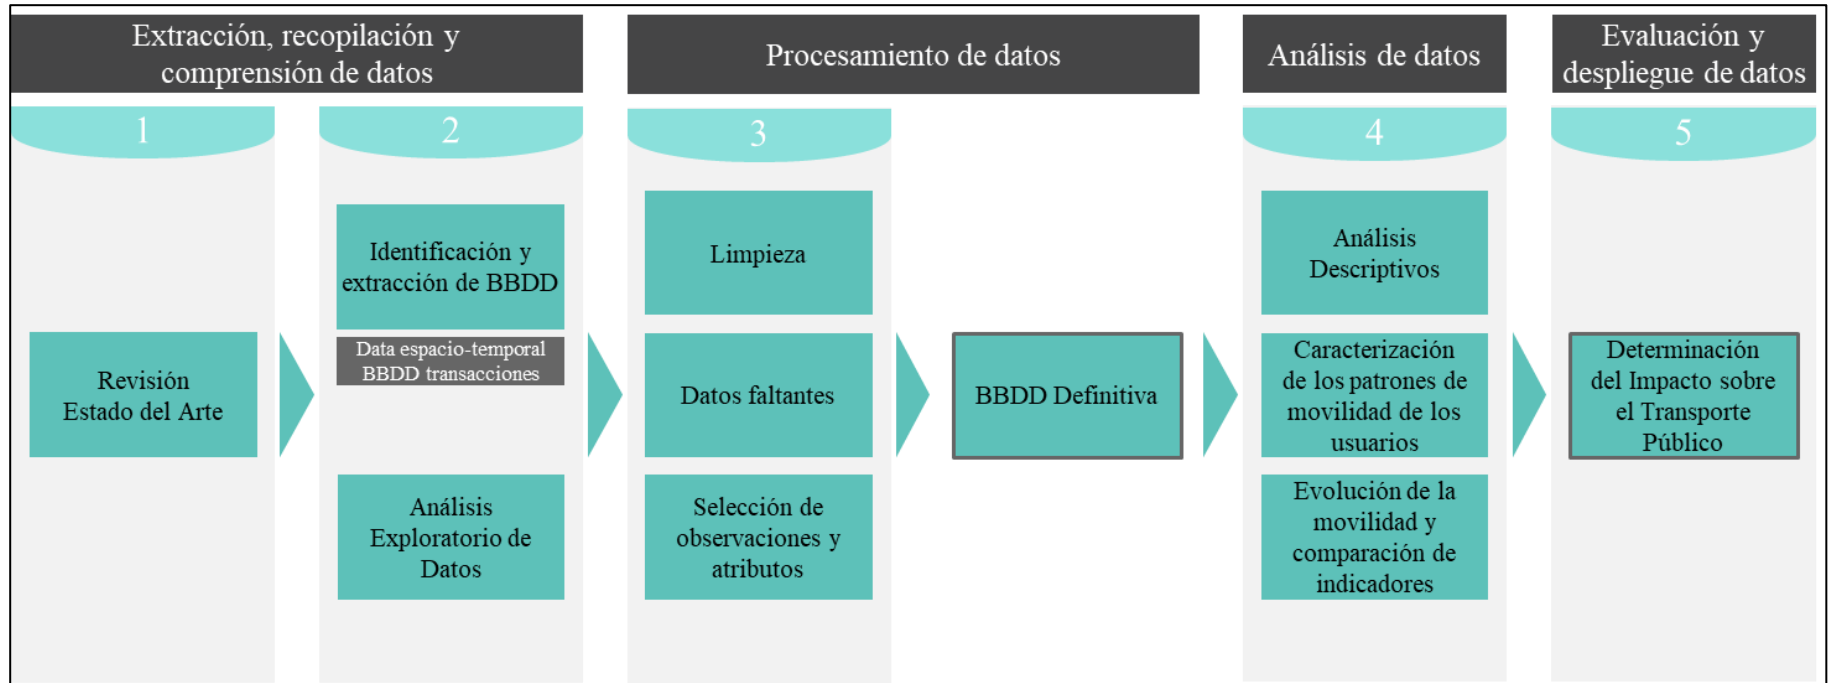
- *Comprensión del área del problema:* Se efectúa una investigación preliminar para entender el contexto del problema y se realiza una revisión del estado del arte.
- *Recopilación de los datos:* Se obtienen las bases de datos de transacciones de transporte público a utilizar y se realiza un análisis exploratorio de ellas mediante herramientas que permitan manejar el volumen y tipo de datos considerados.
- *Preparación y procesamiento de los datos:* Se ejecutan las actividades necesarias para generar las bases de datos definitivas. Entre ellas se incluye el proceso de limpieza, manejo de datos faltantes, y selección de observaciones y atributos que serán usados.

- *Análisis de los datos:* Se efectúan análisis descriptivos agregados de los resultados obtenidos. Se aplican técnicas estadísticas y de visualización de datos para caracterizar los patrones de movilidad de los usuarios del sistema, desde las dimensiones temporal y espacial. Se estudia la evolución de la movilidad en el transcurso de la pandemia por COVID-19, mediante la comparación de indicadores.
- *Evaluación y despliegue de los datos:* Se determina la calidad de los resultados obtenidos, se ejecutan los cambios que se estimen pertinentes y se presentan los análisis desarrollados.

La segunda etapa tiene por finalidad estudiar y determinar los factores que explican la no recuperación total de la movilidad de los usuarios del transporte público, como efecto de la crisis sanitaria, mediante el uso de las técnicas de regresión lineal y regresión espacial. En este caso, se llevan a cabo las siguientes actividades.

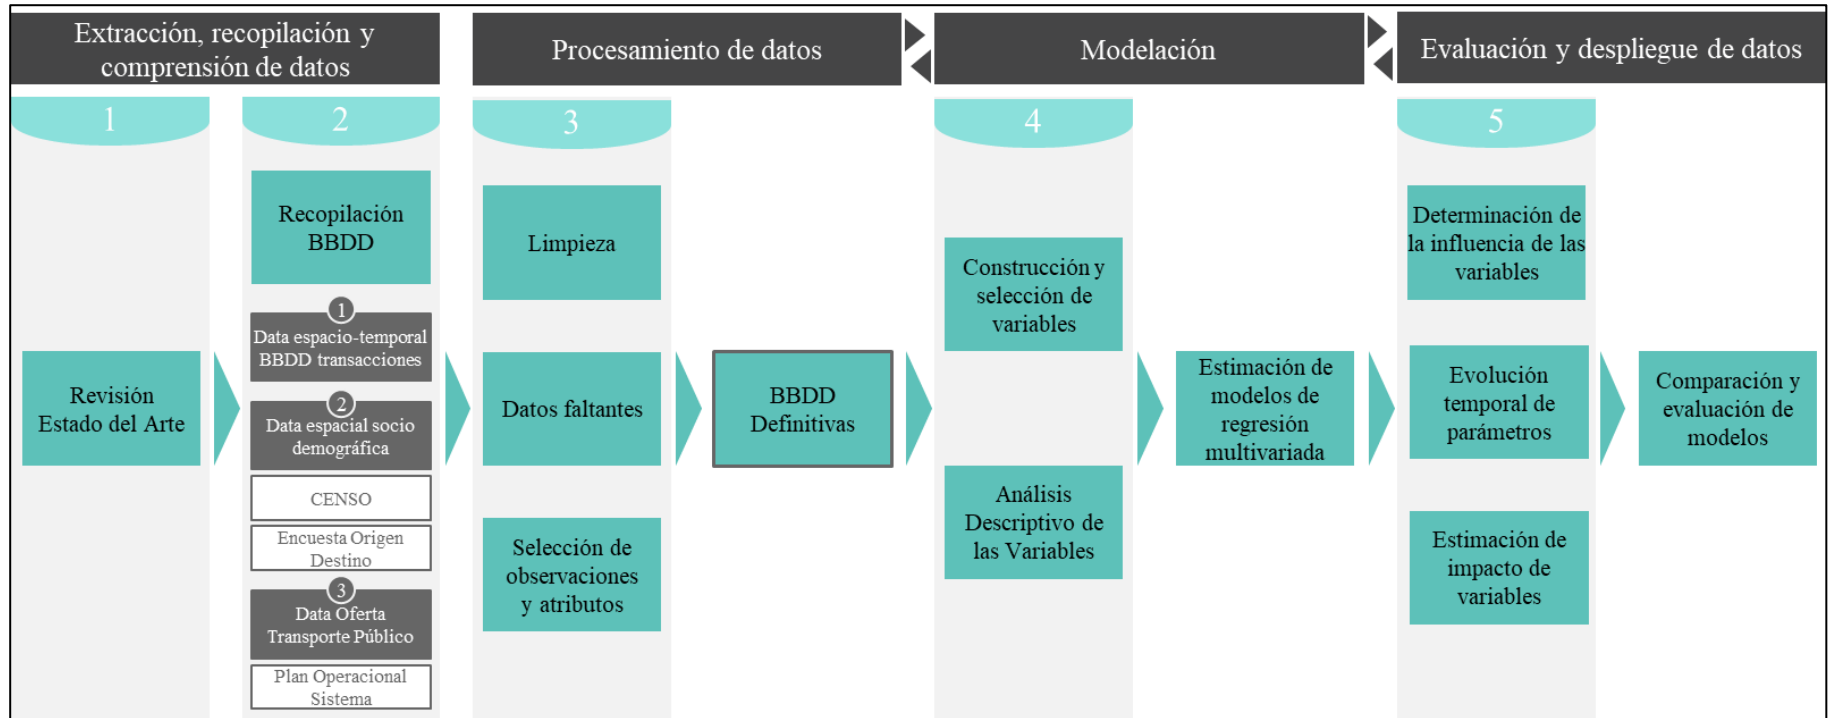
- *Comprensión del área del problema:* Se efectúa una investigación preliminar para entender el contexto del problema y se realiza una revisión del estado del arte de las posibles soluciones.
- *Recopilación de los datos:* Se obtienen las bases de datos que se usarán para generar tanto la variable explicada como las variables explicativas.
- *Preparación y procesamiento de los datos:* Se ejecutan las actividades necesarias para generar las bases de datos definitivas. Entre ellas se incluye el proceso de limpieza, manejo de datos faltantes, selección de observaciones y de atributos que serán usados. Se desarrolla en conjunto con la fase de modelación y se ejecutan cambios de acuerdo con los resultados que se obtengan en cada iteración.
- *Modelación:* En esta fase se diseñan las variables dependientes e independientes que serán usadas para caracterizar el fenómeno estudiado. Se efectúan análisis descriptivos de dichas variables recreadas. Luego, se utilizan y analizan diversas técnicas de modelación. Se estiman los parámetros asociados a cada variable explicativa, mediante modelos de regresión lineal y regresión espacial.
- *Evaluación y despliegue de los datos:* Se determina la influencia de cada variable independiente sobre el fenómeno modelado, a partir de técnicas estadísticas. Se analiza la evolución temporal de los parámetros estimados. Se comparan y evalúan los modelos estimados. Se determina la calidad de los resultados obtenidos y se ejecutan los cambios que se consideren pertinentes. Se presentan los resultados y análisis desarrollados.

Figura 3.1: Diagrama de la metodología general, etapa 1



Fuente: Elaboración Propia

Figura 3.2: Diagrama de la metodología general, etapa 2



Fuente: Elaboración Propia

3.2. Contexto

3.2.1. Sistema de transporte público en Santiago de Chile

La ciudad de Santiago corresponde a la capital de Chile. Está conformada por 34 comunas cuya distribución se aprecia en la figura 3.3. Se caracteriza por agrupar a los principales centros económicos y administrativos, además de ser la aglomeración urbana con mayor población. Se ubica dentro de la Región Metropolitana, la cual, de acuerdo con el último CENSO realizado en el país, supera los 7 millones de habitantes (INE, 2017).


Figura 3.3: Distribución geopolítica comunas de Santiago



Fuente: Ministerio del Interior y Seguridad Pública (2021)

De acuerdo con los resultados entregados por la última Encuesta Origen Destino del año 2012, en un día laboral se efectuaban más de 18 millones de viajes, distribuidos en transporte privado (28%), transporte público (29%), bicicleta (4%), caminata (34%) y otros modos (5%), tal como se aprecia en la figura 3.4.

Figura 3.4: Distribución de viajes diarios en Santiago por modo de transporte



Fuente: Elaboración Propia en base a Muñoz et al. (2015)

En lo que respecta al sistema de transporte público, este opera a través de las 34 comunas de la ciudad de Santiago, cubriendo alrededor de 680 km², y se conoce como Red Metropolitana de Movilidad. Integra de forma física y tarifaria a los buses urbanos, operados por empresas privadas, a la red de Metro y al servicio de tren urbano Estación Central-Nos, mediante un único medio de pago, la tarjeta inteligente Bip!.

Para efectuar el pago de la tarifa, los usuarios deben acercar la tarjeta a un dispositivo llamado validador. Deben repetir esta acción cada vez que suben a algún vehículo, entran a la estación o a la zona paga, no así al bajar o salir de ella. El sistema tarifario es plano, es decir, no considera la distancia recorrida para determinar el cobro. Además, permite realizar hasta tres trasbordos en dos horas. Por otro lado, las tarjetas inteligentes no son personalizadas, por lo que pueden ser compartidas entre los usuarios.

Sobre el sistema de buses, al año 2021 poseía las características que se describen en la tabla 3.1. Cabe señalar que, de los 6.895 vehículos inscritos cerca de 6.250 forman parte de la flota operativa, mientras que los buses restantes son utilizados de reserva y auxiliar. En su mayoría, los buses son de 12 metros de largo, no articulados. En la actualidad, el sistema se encuentra en un proceso gradual de renovación de flota, por lo cual se han adquirido nuevos vehículos eléctricos y ecológicos (32% del total de vehículos operativos).

Tabla 3.1: Características sistema de buses Red

Número de servicios	379
Longitud de la red en km.	2.983
Número de paraderos	11.337
Número de vehículos inscritos	6.895
Millones de kilómetros recorridos al año	357

Fuente: Elaboración Propia en base a DTP (2021)

Los buses son operados diariamente por 6 empresas concesionarias: Subus Chile S.A., Buses Vule S.A., Voy Santiago S.P.A., Buses Metropolitana S.A., Redbus Urbano S.A. y Servicio de Transporte de Personas Santiago S.A. La regulación, control y supervisión del sistema, en búsqueda de mejorar la calidad de vida de los usuarios, son responsabilidad de Directorio de Transporte Público Metropolitano (DTP).

Por otro lado, en las tablas 3.2 y 3.3 se presentan los principales atributos al año 2021 de los sistemas de metro y tren. La red de Metro recorre 26 comunas de la ciudad a través de un trazado principalmente subterráneo, mientras que el servicio de tren Estación Central-Nos permite conectar a la localidad de Nos, ubicada en la comuna de San Bernardo, con Estación Central.

Tabla 3.2: Características sistema de Metro de Santiago

Número de líneas	7
Longitud de la red en km.	140
Número de estaciones	136
Número de trenes	211
Millones de kilómetros recorridos al año	114

Fuente: Elaboración Propia en base a DTP (2021)

Tabla 3.3: Características servicio de Tren Estación Central-Nos


Número de líneas	1
Longitud de la red en km.	20
Número de estaciones	10
Número de trenes	16
Millones de kilómetros recorridos al año	2

Fuente: Elaboración Propia en base a DTP (2021)

En resumen, durante el año 2021 el sistema de transporte público Red registró 754 millones de transacciones y movilizó en promedio a 3,8 millones de usuarios al mes. A la vez, se realizaron más de 527 millones de viajes anuales, 1,8 millones de viajes promedio en día laboral y se recorrieron 472 millones de kilómetros al año (DTP, 2021).


Complementando tales antecedentes, en la figura 3.5 se observa la evolución de las transacciones y viajes anuales en el sistema de transporte público, entre los años 2010 y 2021. Adicionalmente, en la figura 3.6 se muestra la variación en las transacciones totales por año de Red, para el periodo 2012-2021, desagregados por modo.

Figura 3.5: Evolución anual de las transacciones y viajes en transporte público de Santiago



Fuente: DTP (2021). Reproducida con permiso del autor.

Figura 3.6: Evolución anual de las transacciones en transporte público de Santiago, por modo




Fuente: DTP (2021). Reproducida con permiso del autor.

Si bien en el año 2021 Red incrementó el número de transacciones respecto al año 2020, los niveles de validaciones de pago se encuentran por debajo de los valores típicos obtenidos a lo largo de la década. Esta caída se debe principalmente a la pandemia global por COVID-19, cuyo impacto se presencia desde el mes de marzo 2020. En el siguiente acápite se profundizará sobre los efectos que la crisis sanitaria dejó en la ciudad de Santiago.

Otra característica relevante del sistema es su alta evasión al pago de la tarifa. Esto corresponde a la acción de usar el transporte público sin realizar la validación con la tarjeta Bip!, lo cual puede ocurrir en una o varias etapas del viaje. Con ello, se generan diversos problemas, como la incorrecta identificación del lugar de origen o destino del viaje (Amaya, 2013). En la figura 3.7 se entrega la evolución del índice de evasión, medido de manera trimestral en los buses del sistema, entre los años 2013 y 2021.

Figura 3.7: Evolución trimestral del índice de evasión en buses de Santiago



Fuente: DTP (2021). Reproducida con permiso del autor.

Se observa que desde el año 2013 la evasión se encuentra por sobre el 20% y tuvo una tendencia creciente hasta alcanzar un 30% en el año 2017. Posteriormente, en el periodo 2017-2019 se mantuvo en torno al 25%. Finalmente, en los años 2020 y 2021, el índice de evasión fluctuó entre un 30% y 35%, siendo más crítico en los meses iniciales de la pandemia por COVID-19.

3.2.2. COVID-19 en Santiago de Chile

3.2.2.1.Principales hitos de la pandemia en el periodo 2020 - 2021

En diciembre de 2019 comenzó la propagación de un nuevo virus respiratorio desde Wuhan, China, afectando a un gran número de personas. El patógeno, denominado SARS-CoV-2, se expandió rápidamente de forma global, lo cual significó que el 11 de marzo del 2020 la OMS declarara la pandemia. En el caso de Chile, en los inicios del mes de marzo 2020 se detectó a la primera persona contagiada con el virus causante de la enfermedad COVID-19, y desde ese momento se generaron notables cambios en la vida de las personas. En particular, la ciudad de Santiago fue una de las áreas más impactadas por el COVID-19 en lo que respecta a cifras totales de contagiados, mortalidad y letalidad

Una de las primeras medidas implementadas por la autoridad para afrontar la crisis sanitaria fue la suspensión de las clases en establecimientos educacionales el día 15 de marzo de 2020. A ello se sumó el cierre de las fronteras terrestres, marítimas y aéreas del país para el tránsito de personas extranjeras, y la declaración de estado de catástrofe en todo el territorio. Este último restringió la libertad de movimiento y reunión.

El 22 de marzo de 2020 se instauró en Chile el toque de queda, limitando los horarios de tránsito al prohibir la circulación de las personas entre las 22:00 y 05:00 horas, junto con el confinamiento obligatorio para personas mayores de 80 años. Unos días después, la autoridad impuso las primeras medidas de confinamiento global, al declarar en cuarentena total a siete comunas del Gran Santiago: Lo Barnechea, Vitacura, Providencia, Las Condes, Ñuñoa, Santiago Centro e Independencia. Otra de las medidas de aislamiento incorporadas fue el cierre de servicios y comercios no esenciales, como teatros, cines y restaurantes, y la prohibición de realizar eventos que congregaran personas. Adicionalmente, se implementó la obligación de usar mascarilla en lugares públicos y cerrados, junto con el distanciamiento social.

Por otro lado, el 1 de abril del 2020 comenzó a regir la Ley N°21.220, la cual modificaba el Código del Trabajo en aspectos de trabajo a distancia y teletrabajo. Con ello, los empleadores del sector privado podrían establecer horarios laborales flexibles y facilitar el trabajo desde el hogar.

El 13 de mayo de 2020, con la finalidad de controlar la propagación del virus, se decretó la medida de confinamiento obligatorio para la totalidad de las comunas de Santiago, la cual se mantuvo por algunos meses. A la vez, se estableció aislamiento obligatorio para todas las personas mayores de 75 años.

Debido a las diferencias en la incidencia del COVID-19 a lo largo del territorio, el 19 de julio de 2020 la autoridad implementó la estrategia “Paso a Paso”. Esta definía que actividades se podían realizar en cada comuna, en función de los indicadores epidemiológicos y de trazabilidad. El proceso de desconfinamiento contemplaba los cinco pasos que se describen en la tabla 3.4.

Tabla 3.4: Descripción Plan Paso a Paso

Paso	Descripción
Paso 1: Cuarentena	Movilidad limitada, disminuyendo al mínimo la interacción y propagación del virus.
Paso 2: Transición	Se disminuye el grado de confinamiento. Evita la apertura brusca para minimizar los riesgos de contagio. Se mantiene la cuarentena los sábados, domingos y festivos.
Paso 3: Preparación	Se levanta la cuarentena para la población general, exceptuando los grupos de riesgo. Se permiten actividades sociales y recreativas cualquier día de la semana, con un máximo de 50 personas.
Paso 4: Apertura Inicial	Se retoman ciertas actividades de menor riesgo de contagio y minimizan aglomeraciones. Se permite salir de confinamiento una vez al día a adultos mayores de 75 años. Algunos recintos recreativos pueden funcionar con aforo de público. Se implementa el retorno gradual a las clases presenciales de establecimientos educacionales.
Paso 5: Apertura Avanzada	Se permite aumentar la cantidad de gente en actividades, siempre con medidas de autocuidado. Se permite libre movilidad a los adultos mayores de 75 años. Se incrementa el aforo permitido en recintos sociales y recreativos. Se implementa el retorno gradual a las clases presenciales de establecimientos educacionales.

Fuente: Elaboración Propia en base a Ministerio de Salud (2020)

En el periodo de agosto 2020 - diciembre 2020 los contagios tendieron a estabilizarse, con lo cual varias comunas de Santiago fueron avanzando de fase y disminuyendo gradualmente el confinamiento. En efecto, entre el 2 de noviembre y el 13 de diciembre del 2020 prácticamente toda la ciudad se encontró en “preparación” o “apertura inicial”. A su vez, el 23 de noviembre del 2020 se reabrieron fronteras, permitiendo que no residentes pudiesen ingresar a Chile sólo por el Aeropuerto Internacional de Santiago.

El 22 de diciembre de 2020 ingresó al país una nueva variante de COVID-19 y con ello, se observó un incremento en el número de contagios y decesos diarios. A pesar de esto, el 1 de marzo del 2021 se dio inicio al año escolar de forma gradual y presencial, con horarios y jornadas flexibles, y asistencia voluntaria. Posteriormente, el 27 de marzo del 2021 todas las comunas de la Región Metropolitana retornaron a cuarentena obligatoria, manteniéndose la ciudad en esta fase durante el mes de abril 2021. Con ello, la totalidad de los establecimientos educacionales continuaron con sus clases en formato no presencial, al menos hasta el término del primer semestre del año. A la vez, las fronteras del país y el comercio no esencial volvieron a cerrar, mientras que el toque de queda se adelantó, iniciando a las 21:00 horas.

El sábado 12 de junio del 2021 la ciudad de Santiago volvió a entrar, por tercera vez desde el inicio de la pandemia por COVID-19, en cuarentena total. La medida duró dos semanas, dado el descenso en el número de contagios y la “fatiga pandémica” presente en varias comunas que llevaban en confinamiento más de 90 días. Por otro lado, a partir del 26 de julio del 2021 se abrieron fronteras para residentes que hubiesen completado su esquema de vacunación.

En agosto 2021 se dio inicio al segundo semestre escolar, el cual continuó bajo un régimen voluntario por el resto del año. Se mantuvo la tendencia de clases híbridas, mientras que los establecimientos de Educación Superior comenzaron a proyectar su retorno paulatino a las actividades presenciales.

Finalmente, el 30 de septiembre de 2021, después de 560 días, se puso término al estado de excepción y con ello, al toque de queda. Tras el levantamiento de esta restricción, el comercio y servicios retomaron sus horarios habituales, mientras que el transporte público pudo volver a transitar de madrugada. A pesar de que las cuarentenas llegaron a su fin y se permitió realizar cualquier tipo de actividad, los aforos de público se mantuvieron en función de la situación sanitaria en la que se encontrase cada territorio.


3.2.2.2. Impacto en la movilidad

A partir del año 2020 se evidenciaron cambios sustanciales en los patrones de movilidad que caracterizaban a la ciudad de Santiago de Chile. Ello se dio, principalmente, en respuesta a las acciones impuestas por la autoridad para combatir la pandemia global por COVID-19, las cuales incluyeron restricciones a desplazamientos y actividades, tal como fue descrito en el acápite anterior. A esto se suma la opción individual adoptada por algunas personas de viajar menos, con la finalidad de reducir su exposición al virus.

Para analizar la evolución de la movilidad durante los años 2020 y 2021 en distintas comunas de Santiago, se presenta en la figura 3.8 un extracto del visor de movilidad creado por el Instituto Sistemas Complejos de Ingeniería (ISCI) en colaboración con Entel OCEAN, bajo el contexto de la pandemia por COVID-19. En su elaboración, se utilizaron datos estadísticos e información del uso de infraestructura de telecomunicaciones, agrupado a nivel de zona censal.

La figura 3.7 muestra el cambio del flujo semanal fuera de la zona hogar, en relación a las semanas de referencia (dos primeras semanas de marzo 2020). El flujo semanal se refiere al movimiento desde cada zona hogar (donde las personas se encuentran frecuentemente en horarios de pernoctación) hacia otras zonas, durante horarios de trabajo, para cada día laboral (lunes a viernes). Luego, se calculan los promedios de los flujos semanales a nivel de comuna, excluyendo fines de semana y feriados (ISCI, 2022).

Figura 3.8: Evolución temporal de la movilidad, para diferentes comunas de Santiago, periodo 2020 - 2021



Fuente: ISCI – Entel OCEAN (2022). Reproducida con permiso del autor.

Múltiples análisis se pueden realizar a partir de la figura anterior. En efecto, es posible ver que los días posteriores a la suspensión de clases en la ciudad de Santiago, la movilidad decayó entre un 30% y un 55%. Las comunas de Vitacura y Las Condes presentaron una mayor caída, mientras que en Puente Alto, comuna periférica con menor nivel de ingreso, la reducción fue menor. Esto refleja las primeras diferencias en el comportamiento de la movilidad en función de la situación socioeconómica de la comuna.

Si bien, se evidencia una leve recuperación, al implementar la medida de cuarentena total en la ciudad de Santiago la movilidad volvió a caer. Entre los meses de mayo 2020 y julio 2020, existió un incremento gradual del indicador, a pesar de que durante ese periodo las comunas se encontraron bajo completo confinamiento.

Posteriormente, entre los meses de agosto 2020 y noviembre 2020, la movilidad en la ciudad aumentó, coincidente con el levantamiento de restricciones y el paso de las comunas a las fases de transición, preparación y apertura inicial. Por un lado, Vitacura y Las Condes alcanzaron niveles de -25% respecto a la semana de referencia. Las comunas de Ñuñoa y Santiago se acercaron a una movilidad de -20%, mientras que Puente Alto y Quinta Normal mostraron la mayor recuperación, aproximándose a -15% y -10% respectivamente.

Entre los meses de diciembre 2020 y marzo 2021, la movilidad no mostró mayores fluctuaciones, variando entre -30% y -10% en comparación con la semana base, dependiendo de la comuna. Sin embargo, los confinamientos totales implementados en abril 2021 y junio 2021 ocasionaron nuevas caídas en la movilidad observada, de menor envergadura que las registradas un año atrás.

En efecto, estas dos últimas cuarentenas no tuvieron el mismo impacto en la movilidad que la primera. Comunas como Quinta Normal, Puente Alto y Santiago Centro presentaron una movilidad estable en torno a -20% y -30% entre los meses de abril 2021 y junio 2021. Por otro lado, en las comunas de Las Condes, Vitacura y Ñuñoa si bien se observaron caídas en las semanas de confinamiento, la movilidad disminuyó a lo más entre un -35% y -45%.

En el periodo julio 2021 – diciembre 2021 se evidencia un aumento paulatino de la movilidad en todas las comunas consideradas, en línea con las menores restricciones de desplazamiento y actividades existentes en ese entonces. Al cierre del año 2021, las comunas de Las Condes, Vitacura y Ñuñoa tuvieron niveles de movilidad en torno al -20%, en comparación con la semana de referencia de marzo 2020, mientras que Quinta Normal, Puente Alto y Santiago Centro presentaron un indicador en torno a -10% y -5%.


Por último, es importante destacar que durante el primer semestre del año 2022, la movilidad se recuperó por completo, respecto a los valores medidos previo a la pandemia, en algunos sectores de la ciudad, como Quinta Normal, Puente Alto y Santiago Centro. Por el

contrario, en las comunas del sector oriente de la ciudad analizadas (Las Condes, Vitacura y Ñuñoa), la movilidad aún se encuentra levemente por debajo de los niveles referenciales.

Medidas como la suspensión de clases en establecimientos educacionales, cierre de servicios y comercios no esenciales, confinamientos parciales y totales por comunas, fueron implementadas por la autoridad en el transcurso de la pandemia por COVID-19 con la finalidad de evitar aglomeraciones y minimizar los contagios. Si a la vez se considera el fuerte crecimiento que tuvo el comercio electrónico, implementación del teletrabajo en algunos rubros, y el aumento en el uso del automóvil y de la bicicleta, es posible explicar gran parte de los cambios identificados anteriormente, en los desplazamientos típicos de la ciudad.

Con respecto al teletrabajo, uno de los efectos de la emergencia sanitaria ha sido el aumento en el número de personas que trabajan a distancia, generalmente desde sus casas. A partir de los Boletines Complementarios al Informe de Remuneraciones y Costo de la Manos de Obras elaborado mensualmente por el INE desde abril 2020, se generó la figura 3.9. En ella se muestra la evolución del porcentaje de trabajadores que realizaron sus tareas de forma remota desde el hogar, trabajo a distancia o teletrabajo, en base a los resultados de la Encuesta Mensual de Remuneraciones aplicada a más de 1.000 empresas del país.

Figura 3.9: Evolución del porcentaje de personas con trabajo a distancia, periodo 2020 - 2021



Fuente: Elaboración Propia en base a INE (2022)

Se evidencia un porcentaje superior al 20% durante todo el año 2020, alcanzando la cifra, en promedio, de uno cada cuatro trabajadores con labores a distancia. En el año 2021 la tendencia

fue a la baja, considerando que varias funciones retornaron a la presencialidad. Con ello, una de cada diez personas trabajadoras de empresas formales realizó trabajo remoto en diciembre 2021.

Sobre los sectores que concentran la mayor cantidad de empresas bajo la modalidad de teletrabajo, a fines del año 2021 se destacaban los rubros de: Información y Comunicaciones, Administración Pública, Suministro de Electricidad y Gas, y Actividades Financieras y de Seguros. Por otro lado, los sectores que registraron un menor uso de la modalidad a distancia fueron Construcción, Alojamiento y Servicios de Comida e Industria Manufacturera.

Otra de las repercusiones que tuvo la pandemia del COVID-19 fue el crecimiento del comercio electrónico, también conocido como e-commerce. Ello se debió principalmente a las cuarentenas implementadas y al cierre de tiendas físicas, restaurantes, entre otros. Con ello, las modalidades de compra y venta se vieron en la obligación de cambiar. En concreto, de acuerdo con lo indicado por la Cámara de Comercio de Santiago (CCS), el comercio electrónico aumentó un 55% en 2020 y un 23% en 2021, respecto al año anterior.


Por otro lado, el uso del automóvil y la bicicleta se ha visto favorecido por la crisis sanitaria. La búsqueda de modos alternativos que permitan evitar las aglomeraciones junto a la sensación de inseguridad y miedo a contagiarse en el transporte público ha generado que las personas opten por los vehículos privados, o bien por los ciclos, como medio de transporte.

Sobre la preferencia por el automóvil, de acuerdo con los datos de la Asociación Nacional Automotriz de Chile (ANAC), el total de ventas de vehículos livianos y medianos creció un 57% el año 2021 en la Región Metropolitana. Esto se complementa con las estadísticas entregadas por el INE, donde el volumen de permisos de circulación tramitados en el país durante el año 2021 aumentó un 9,2%, en comparación con el año 2020 marcado por medidas sanitarias y restricciones de movilidad. Paralelamente, una encuesta realizada a más de 2.000 personas por CADEM a inicios del año 2022 arrojó que un 71% de los hogares del poseen un automóvil. Dentro de los atributos que más valoraron de este modo fue la comodidad, seguridad y rapidez.

En relación con el mayor uso de la bicicleta, MTT (2021) estima que hubo un crecimiento en el número de viajes diarios en la pandemia, en torno al 10% a nivel país, respecto a la demanda catastrada el 2019. Además, este modo se ha visto favorecido por el incremento en la infraestructura especializada para la circulación de ciclos. En efecto, de acuerdo con la información entregada por MTT (2021), solo en la Región Metropolitana se construyeron 255 kilómetros nuevos de ciclovías en el periodo 2018-2021, lo cual representa un crecimiento aproximado del 51%.


En lo que respecta al comportamiento del transporte público, en las figuras 3.10 y 3.11 se observa la evolución de mensual de las transacciones, viajes y usuarios del sistema a lo largo de la última década. Se evidencia una fuerte caída en marzo 2020, coincidente con los inicios de la pandemia por COVID-19.

Figura 3.10: Evolución mensual de las transacciones y viajes en transporte público de Santiago



Fuente: DTP (2021). Reproducida con permiso del autor.

Figura 3.11: Evolución del promedio mensual de usuarios del sistema de transporte público de Santiago



Fuente: DTP (2021). Reproducida con permiso del autor.

Complementando, de acuerdo con los antecedentes entregados por el Ministerio de Transporte y Telecomunicaciones (2020), en el primer día hábil de cuarentena total en Santiago, las validaciones mediante la tarjeta Bip! disminuyeron aproximadamente un 86%, en comparación con la semana del 9 al 13 de marzo de 2020, previo a la incorporación de restricciones en la ciudad.

En el periodo 2020-2021 se refleja el impacto de las medidas sobre la demanda en transporte público. Si bien existió una recuperación en el número de transacciones, viajes y usuarios del sistema, a finales del año 2021 es posible notar que los niveles se encuentran por debajo de los registrados antes de la emergencia sanitaria.

Además de los cambios antes representados, el regulador del sistema implementó una serie de acciones con el objetivo de evitar contagios y recuperar la confianza de los usuarios en el transporte público. Entre estas, se destaca la sanitización diaria de buses, paraderos, vagones y estaciones de metro y tren, la intervención de paradas de buses con demarcación en asientos y andenes para incentivar el distanciamiento físico durante la espera, y la realización de campañas para promover medidas de autocuidado, como el uso de mascarilla en los trayectos (DTP, 2021).

3.3. Recopilación y generación de datos

Los datos usados en el trabajo de investigación entregan información real y desagregada de la operación del transporte público en la ciudad de Santiago de Chile. Para su obtención se realiza el cruce entre los datos del sistema de posicionamiento de vehículos basado en GPS y el flujo de pasajeros observado gracias al software de Análisis de Datos de Transporte Público, ADATRAP, basado en las transacciones de pago mediante tarjetas inteligentes.

Respecto al cruce de los sistemas, el cual permite identificar la ubicación y hora de subida del usuario de transporte público, este dependerá del modo en el cual se realice la validación del pago. En primer lugar, cuando un pasajero viaja en metro o tren, el lugar de subida se obtiene de manera automática y corresponde a la posición de la estación de metro, dado que los dispositivos donde se efectúa la transacción son fijos y se encuentran al interior de la estación.

En el caso de los buses, se debe considerar que los vehículos cuentan con dispositivos GPS, de forma tal que su posición geográfica es entregada por el proveedor tecnológico cada 30 segundos. Luego, cuando el usuario aborda al bus y acerca su tarjeta Bip! al validador, se almacena información del ID de la tarjeta y la hora en que se efectuó la transacción. Con ello, el paradero de subida se obtiene relacionando la hora de las posiciones del GPS con la de la validación, para posteriormente estimar la posición del bus en el instante que se ejecutó la transacción y determinar el paradero que se encuentra más próximo.

Por último, si el pasajero realizó la validación en una zona paga, correspondiente a los sitios donde los validadores se localizan en el paradero por lo cual el usuario debe pagar su pasaje antes de abordar el bus, la metodología es similar al caso de las estaciones de metro y tren, considerando

que son zonas estáticas y preestablecidas. Sin embargo, la asignación del bus al que sube el usuario no es directa.

Por lo tanto, cada vez que un pasajero aproxima su tarjeta inteligente a un validador, ya sea en estaciones de metro o tren, en un bus o zona paga, se realiza una transacción, la cual recoge información de la subida, que se utiliza en análisis posteriores del sistema. Respecto a la bajada, dado que el usuario no debe validar su tarjeta al abandonar el sistema, no existen registros directos que permitan obtener información de la ubicación y hora en que esta se efectúa. Es por lo que se aplica la metodología de Munizaga y Palma (2012) descrita en el capítulo 2, la cual permite estimar la bajada para un gran volumen de transacciones y contar con el destino de los viajes realizados por los usuarios.

En resumen, las bases de datos pasivos a utilizar contienen, para cada transacción, información de los atributos que se caracterizan en la siguiente tabla. Estos se obtienen, en su mayoría, directamente de los registros proporcionados. Otras variables, como las relacionadas con la estimación de bajada, y las agrupaciones de transacciones en etapas y viajes, son calculadas gracias a post-procesamientos de los atributos originales, mediante el software ADATRAP.

Tabla 3.5: Descripción de variables relevantes en bases de datos de transacciones en transporte público

Variable	Descripción
ID	Número identificador asociado a la tarjeta inteligente con que se realizó la transacción. No entrega información personal del propietario.
Número del viaje	Número entero correlativo estimado que indica el orden temporal de cada viaje realizado en el día. Se asigna a cada una de las etapas que conforman un mismo viaje, siguiendo reglas temporales y espaciales.
Número de la etapa	Número entero correlativo que indica el orden temporal de cada transacción realizada en un mismo viaje.
Tipo de día	Variable que señala el tipo de día en el que se efectuó la transacción. Toma los valores de laboral, sábado o domingo.
Tipo de transporte	Variable que señala el tipo de transporte en el cual se realizó la transacción. Toma los valores de bus, metro, tren o zona paga.
Tiempo de subida	Fecha y hora en la que se realiza la validación de la tarjeta.
Tiempo de bajada	Fecha y hora estimada en la que el usuario se baja del vehículo. Indica el término de la etapa de viaje para cada transacción.
Coordenadas de subida	Coordenadas (x,y), en UTM, donde se efectuó la validación.
Coordenadas de bajada	Coordenadas (x,y) estimadas, en UTM, donde el pasajero se bajó del vehículo.
Servicio de subida	Nombre de la línea de metro, de tren o servicio-sentido de bus donde se realizó la transacción.
Paradero de subida	Nombre de la estación de metro, de tren, código del paradero de bus o zona paga donde se efectuó la validación.
Paradero de bajada	Nombre de la estación de metro, de tren, código del paradero de bus o zona paga donde se estima la bajada del usuario.
Comuna de subida	Comuna donde se localiza el lugar de subida.
Comuna de bajada	Comuna donde se ubica el lugar de bajada estimado.
Distrito censal de subida	Distrito censal donde se localiza el lugar de subida. Variable estimada.

Fuente: Elaboración Propia en base a ADATRAP

En el capítulo 4 se identifica el tamaño de las bases de datos y se entrega un análisis descriptivo de ellas, considerando que cada observación corresponde a la información de una transacción en el sistema.

3.4. Descripción de los cortes temporales en estudio

El presente trabajo se enfoca en estudiar los cambios en los patrones de movilidad del transporte público de la ciudad de Santiago de Chile, debido a la pandemia por COVID-19, e identificar los factores que inciden en la no recuperación de los usuarios del sistema. Para ello, se analizan y comparan seis bases de datos, representativas de diferentes escenarios, las cuales contienen información de las transacciones efectuadas en seis semanas no consecutivas.

Tabla 3.6: Definición cortes temporales a estudiar

Corte temporal	Día inicio	Día término	Año
Marzo 2020	9 de marzo	15 de marzo	2020
Mayo 2020	25 de mayo	31 de mayo	2020
Julio 2020	20 de julio	26 de julio	2020
Noviembre 2020	2 de noviembre	8 de noviembre	2020
Julio 2021	26 de julio	1 de agosto	2021
Noviembre 2021	8 de noviembre	14 de noviembre	2021

Fuente: Elaboración Propia

El primer corte temporal de marzo 2020 corresponde a la semana anterior a la cual se suspendieron las clases en establecimientos educacionales. Por lo tanto, se considera como semana de referencia, representativa de la situación previa a la pandemia por COVID-19. A su vez, el corte temporal de mayo 2020 representa una de las primeras semanas en la que toda la ciudad de Santiago se encontró bajo total confinamiento. Luego, las restricciones de desplazamiento y actividades eran múltiples, por lo que los niveles de movilidad son mínimos.

En la semana de julio 2020 todas las comunas de Santiago seguían en cuarentena total, es decir, existían las mismas limitaciones para desplazarse que en el corte temporal anterior. No obstante, se registraron aumentos en la movilidad cuya causa es desconocida. Por otro lado, la semana de noviembre 2020 se caracterizó por el menor grado de confinamiento en la ciudad, por tanto, la movilidad en transporte público fue de las mayores observadas durante el año transcurrido.

El corte temporal de julio 2021 se encuentra semanas después del término de la última cuarentena total implementada en Santiago. Al mismo tiempo, corresponde a la semana anterior al retorno a clases híbridas en establecimientos educacionales. Por tanto, presenta mayores niveles de movilidad. Finalmente, el corte temporal de noviembre 2021 representa los avances hacia una nueva “normalidad” en la ciudad. Las restricciones de desplazamiento y actividades prácticamente se habían levantado por completo, por lo cual la movilidad en transporte público mostraba una alta recuperación, aunque aún por debajo de los niveles observados previos a la crisis sanitaria.

Capítulo 4: Análisis Agregado de Patrones de Movilidad

Con el objetivo de caracterizar de manera agregada el comportamiento de los usuarios del transporte público y estudiar la evolución de su movilidad en el transcurso de la pandemia por COVID-19, se presenta en el siguiente capítulo un análisis descriptivo de las bases de datos pasivos disponibles.

El uso de estos datos, alimentados por la existencia del pago sin contacto a través de la tarjeta inteligente y el sistema de GPS en buses, entrega información masiva, de mucha utilidad y a bajo costo de la operación del transporte público en la ciudad de Santiago de Chile.

El análisis es abordado desde diversas dimensiones. En primer lugar, se estudiarán las transacciones registradas en cada día, se obtendrán perfiles horarios de la demanda y se realizará una desagregación por modo de transporte. Luego, se describirá el comportamiento en el tiempo de los viajes y tarjetas usadas en el transporte público, considerando sus respectivas limitaciones. Posteriormente, se efectuará un análisis espacial a nivel comunal. Por último, se presentarán estadísticas de viajes con origen en el hogar, a partir de imputaciones basadas en la literatura existente.

4.1. Análisis de transacciones

En este apartado se sintetiza la información obtenida de los datos de transacciones para cada semana representativa en estudio descritas en el capítulo 3, desde una perspectiva temporal. Para comenzar, en la tabla que sigue se muestra el número de transacciones registradas en el sistema cada día de la semana, para seis cortes temporales: marzo 2020, mayo 2020, julio 2020, noviembre 2020, julio 2021 y noviembre 2021.

Tabla 4.1: Transacciones registradas por día de la semana y corte temporal

Día	Marzo 2020	Mayo 2020	Julio 2020	Noviembre 2020	Julio 2021	Noviembre 2021
Lunes	4.263.634	634.407	770.753	2.204.332	2.618.901	3.267.156
Martes	4.521.695	606.553	639.349	2.180.118	2.613.578	3.283.087
Miércoles	4.048.813	596.522	738.239	2.220.145	2.650.640	3.329.159
Jueves	4.330.360	595.018	719.859	2.234.181	2.678.435	3.305.934
Viernes	4.315.505	627.726	759.451	2.328.833	2.815.406	3.363.021
Promedio Laboral	4.296.001	612.045 (-86%)	725.530 (-83%)	2.233.522 (-48%)	2.675.392 (-38%)	3.309.671 (-23%)
Sábado	2.191.764	360.582	430.097	1.357.063	1.664.477	1.974.425
Domingo	1.150.367	201.248	235.508	755.344	999.221	1.115.394
Total Semanal	24.822.138	3.622.056 (-85%)	4.293.256 (-83%)	13.280.016 (-46%)	16.040.658 (-35%)	19.638.176 (-21%)

Fuente: Elaboración Propia en base a ADATRAP


Es posible observar que en los inicios de la pandemia por COVID-19 existió una caída considerable en el total de transacciones diarias, alcanzando un 86% de reducción respecto al promedio laboral registrado en marzo 2020. Por otro lado, en la semana de julio 2020 se evidencia un aumento de la movilidad en transporte público en comparación con mayo 2020, a pesar de que en ambas semanas la ciudad de Santiago se encontraba bajo confinamiento obligatorio y los desplazamientos estaban restringidos al máximo. Se puede notar también que, si bien en el transcurso de la crisis sanitaria el total de transacciones diarias ha aumentado, a noviembre 2021 aún no se recuperaban los niveles de demanda medidos en la semana de marzo 2020, registrándose un 23% menos de transacciones en el día promedio laboral.

En la figura 4.1 se presenta la distribución horaria de las transacciones para cada tipo de día y corte temporal, para lo cual se considera la hora en la que se realizó la validación, es decir, la hora de inicio de una etapa del viaje. Se observa que, en los cortes temporales de mayo 2020, julio 2020, noviembre 2020 y julio 2021 las transacciones se concentran entre las 05:00 y las 22:00 horas para los distintos tipos de día. Lo anterior coincide con la medida tomada por la autoridad de instaurar “toque de queda”, referente a la prohibición de circular libremente en ciertos horarios del día. En noviembre 2021, el toque de queda fue levantado, por lo cual se evidencia como la curva se desplaza hacia la derecha acercándose a la de marzo 2020, debido a la presencia de transacciones en horario nocturno.

Respecto al día tipo laboral, la existencia de los periodos punta mañana y punta tarde se mantuvo incluso en los primeros meses de pandemia, a diferencia de los días sábado y domingo donde se tiene una distribución más uniforme a lo largo del día. Se puede notar también que las puntas se achatan y que prácticamente en todos los cortes temporales pandémicos el peak de transacciones en la mañana se adelantó desde las 07:30 a las 07:00 horas, mientras que en el corte temporal de noviembre 2021 se retoma el comportamiento existente previo a la crisis sanitaria. A su vez, la hora en la que se alcanza el máximo de transacciones en la tarde no sufre variaciones, manteniéndose a las 18:00 horas. Se observa que durante el transcurso de la pandemia en el año 2020 la punta característica al medio día se aplanó, volviendo a identificarse claramente en el corte temporal de noviembre 2021.

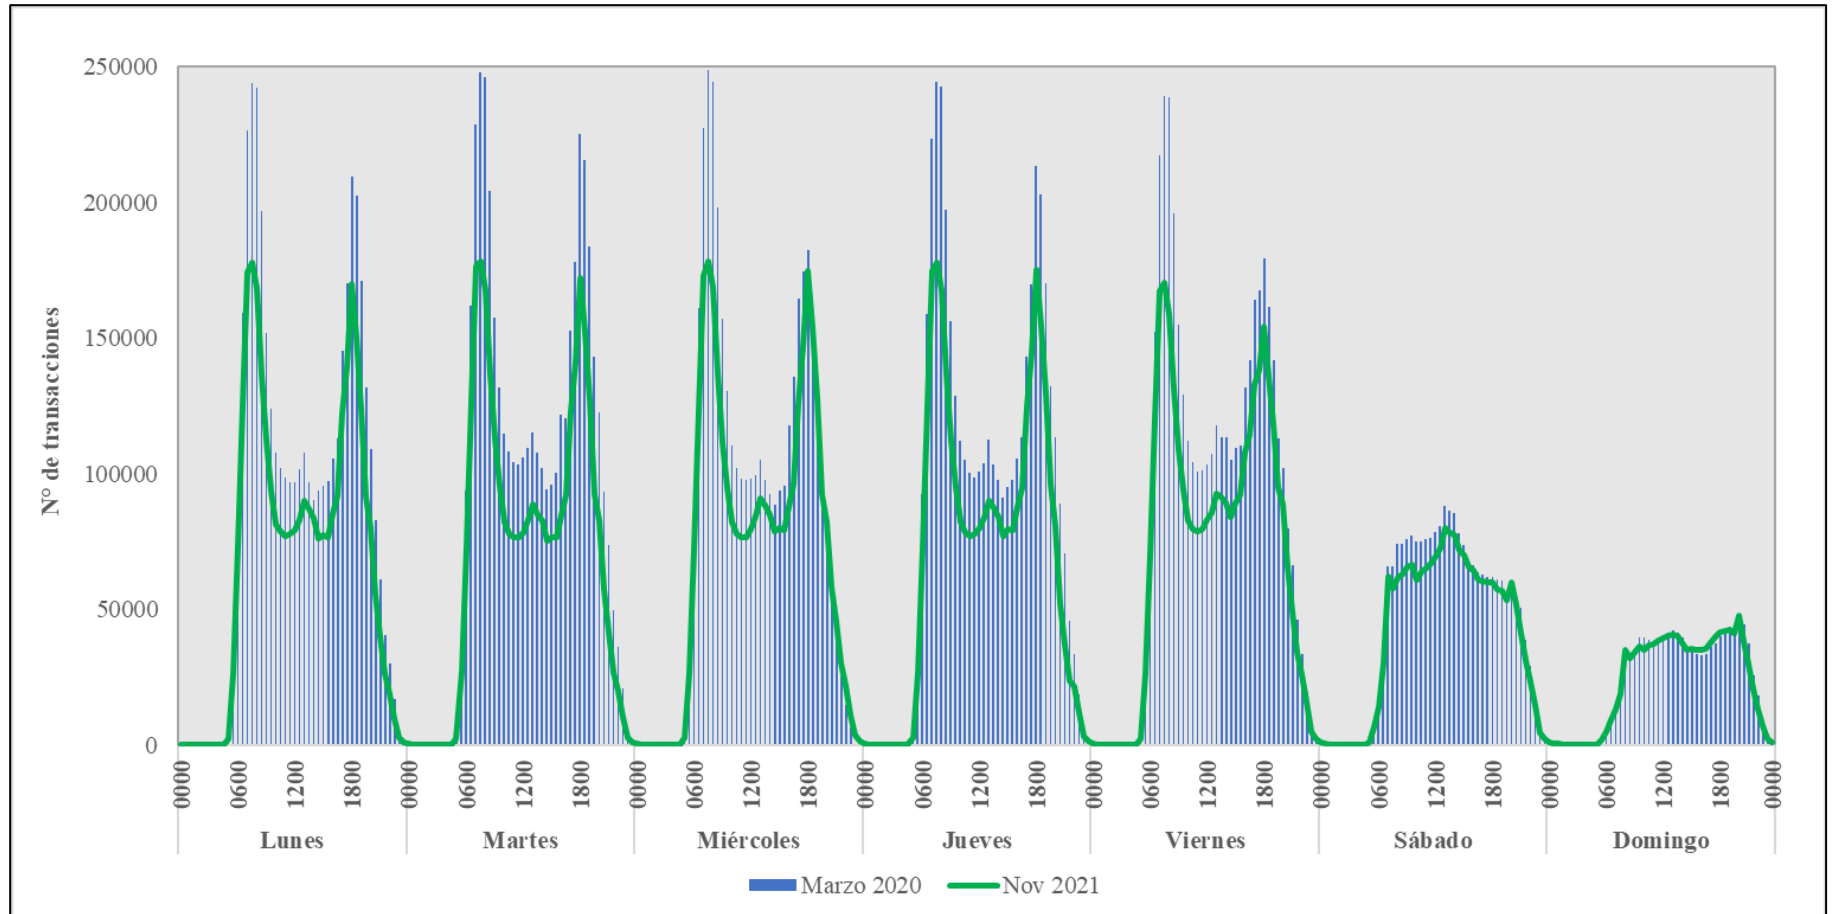
Por otro lado, la recuperación de la movilidad del transporte público durante los fines de semana ha sido mayor que la de los días laborales. En efecto, a noviembre 2021 se tenía una caída en las transacciones de los días tipo sábado y domingo del 10% y 3% respectivamente, en comparación con los niveles registrados previo a la pandemia por COVID-19. Esto se puede verificar en la figura 4.2, donde la curva con la distribución horaria de las transacciones registradas en noviembre 2021 se aproxima bastante a la de marzo 2020.

Figura 4.1: Perfil horario de transacciones por tipo de día y corte temporal



Fuente: Elaboración Propia en base a ADATRAP

Figura 4.2: Comparación de los perfiles horarios de transacciones, cortes temporales de marzo 2020 y noviembre 2021



Fuente: Elaboración Propia en base a ADATRAP

En la siguiente tabla 4.2 y figura 4.3 se presenta la distribución de las transacciones desagregadas por modo, tipo de día y corte temporal. Entre los modos de transporte público disponibles se encuentran: bus, metro, tren y zona paga. Sin embargo, las transacciones realizadas en zonas pagas también se efectúan en el modo bus, por lo que son adicionadas a este último.


Tabla 4.2: Transacciones registradas por modo, tipo de día y corte temporal

Día	Modo	Marzo 2020	Mayo 2020	Julio 2020	Noviembre 2020	Julio 2021	Noviembre 2021
Laboral	Bus	2.176.942 (51%)	335.792 (55%)	397.575 (55%)	1.130.871 (51%)	1.359.033 (51%)	1.644.721 (50%)
	Metro	2.045.228 (48%)	263.864 (43%)	313.614 (43%)	1.059.202 (47%)	1.271.190 (48%)	1.608.253 (49%)
	Tren	73.831 (2%)	12.389 (2%)	14.341 (2%)	43.449 (2%)	45.169 (2%)	56.698 (2%)
	Total	4.296.001	612.045	725.530	2.233.522	2.675.392	3.309.671
Sábado	Bus	1.169.800 (53%)	200.787 (56%)	238.094 (55%)	650.803 (48%)	812.086 (49%)	910.174 (46%)
	Metro	976.885 (45%)	152.395 (42%)	183.242 (43%)	676.175 (50%)	820.064 (49%)	1.024.814 (52%)
	Tren	45.079 (2%)	7.400 (2%)	8.761 (2%)	30.085 (2%)	32.327 (2%)	39.437 (2%)
	Total	2.191.764	360.582	430.097	1.357.063	1.664.477	1.974.425
Domingo	Bus	646.104 (56%)	115.641 (57%)	134.667 (57%)	373.368 (49%)	502.302 (50%)	553.661 (50%)
	Metro	479.007 (42%)	80.676 (40%)	95.186 (40%)	364.066 (48%)	476.203 (48%)	539.539 (48%)
	Tren	25.255 (2%)	4.931 (2%)	5.655 (2%)	17.910 (2%)	20.716 (2%)	22.194 (2%)
	Total	1.150.366	201.248	235.508	755.344	999.221	1.115.394

Fuente: Elaboración Propia en base a ADATRAP

Con respecto al día promedio laboral, se puede ver que previo a la pandemia por COVID-19 las particiones de bus y metro eran bastante parejas; un 51% de las transacciones que se realizaron fueron para abordar un bus, mientras que un 48% se efectuaron en estaciones de Metro y un 2% en estaciones de tren. En los inicios de la emergencia sanitaria la partición de bus aumentó a un 55% y la de metro se redujo a un 43%. Con el paso del tiempo, las proporciones recuperaron la distribución mostrada en la situación inicial, no obstante, ningún modo alcanzó a esa fecha los niveles de demanda observados en día laboral.

Figura 4.3: Transacciones por modo, tipo de día y corte temporal



Fuente: Elaboración Propia en base a ADATRAP

Para los días sábado y domingo el análisis es similar. Antes de la pandemia, el modo bus capturaba incluso una mayor participación que durante los días laborales, con un 53% de las transacciones del sábado y un 56% del domingo. En el comienzo de la crisis sanitaria, dicha participación se incrementó y el modo bus alcanzó un 56% y 57% de las validaciones de los días sábado y domingo respectivamente. Luego, en el transcurso de la pandemia, ambas proporciones se estabilizaron. Es por ello que en el corte temporal de noviembre 2021 se observa que las transacciones en estaciones de Metro representan el 52% del total del sábado, con lo que supera a la participación de bus, y un 48% del domingo. Es importante notar también que las transacciones en metro realizadas durante los fines de semana sobrepasaron en noviembre 2021 a los niveles de demanda registrados en la situación inicial. Por otro lado, la participación del tren se mantiene constante en un 2% en cada corte temporal analizado.

Finalmente, se debe recordar que los datos de transacciones entregan directamente información de la hora y ubicación geográfica en la que el usuario realizó la validación de su tarjeta Bip! para abordar al sistema de transporte público. Sin embargo, la estimación de la bajada se obtiene mediante post-procesamientos de los datos, basados en la observación de la siguiente transacción de la misma tarjeta (Munizaga y Palma, 2012). Luego, no todas las transacciones recopiladas poseen información de su bajada. En la tabla 4.3 se desglosa el total de transacciones cuyo paradero de bajada logró ser estimado y se indica entre paréntesis el porcentaje de éxito del proceso.

Tabla 4.3: Transacciones con bajada estimada y porcentaje de éxito, por día de la semana y corte temporal

Día	Marzo 2020	Mayo 2020	Julio 2020	Noviembre 2020	Julio 2021	Noviembre 2021
Lunes	3.244.585 (76%)	440.574 (69%)	538.641 (70%)	1.642.937 (75%)	1.987.940 (76%)	2.513.602 (77%)
Martes	3.074.623 (68%)	428.383 (71%)	456.029 (71%)	1.650.905 (76%)	2.006.683 (77%)	2.553.414 (78%)
Miércoles	3.017.347 (75%)	421.184 (71%)	524.028 (71%)	1.681.432 (76%)	2.031.260 (77%)	2.586.406 (78%)
Jueves	3.308.955 (76%)	420.384 (71%)	511.327 (71%)	1.688.617 (76%)	2.042.028 (76%)	2.557.582 (77%)
Viernes	3.247.582 (75%)	436.735 (70%)	531.789 (70%)	1.723.192 (74%)	2.101.098 (75%)	2.550.805 (76%)
Promedio Laboral	3.178.618 (74%)	429.452 (70%)	512.363 (71%)	711.770 (75%)	2.033.802 (76%)	2.552.362 (77%)
Sábado	1.536.461 (70%)	228.523 (63%)	272.395 (63%)	934.256 (69%)	1.158.818 (70%)	1.398.319 (71%)
Domingo	755.034 (66%)	119.636 (59%)	141.302 (60%)	489.284 (65%)	660.077 (66%)	743.365 (67%)
Total Semanal	18.184.587 (73%)	2.495.419 (69%)	2.975.511 (69%)	9.810.623 (74%)	11.987.904 (75%)	14.903.493 (76%)

Fuente: Elaboración Propia en base a ADATRAP

Se observa que el porcentaje de transacciones cuya baja ha sido estimada exitosamente ronda el 70% en cada corte temporal analizado. En general, se tiene una mayor captura de la información durante los días laborales. Entre las posibles fuentes de error que impiden obtener una estimación del paradero de bajada para cada subida, se encuentran: solo se realiza una transacción por día, se imputa una distancia no caminable, se estima la bajada y la subida en el mismo sitio, se asigna de manera errónea el destino de un viaje a uno de los lugares donde se efectuaron trasbordos, existen errores en los datos, entre otras.

Por otro lado, se nota de la tabla 4.3 que en los inicios de la pandemia por COVID-19 la tasa de éxito fue menor, sin embargo, se recuperó paulatinamente con el paso del tiempo. Respecto a la caída medida en los cortes de mayo y julio 2020, esta resultó más significativa en los días sábado y domingo (-7%), en comparación con el día laboral promedio (-4%). Ello puede explicarse por el aumento en los niveles de evasión del pago de la tarifa de transporte público, debido a la decisión de algunos operadores del sistema de permitir a los usuarios abordar a los buses por la puerta trasera. La medida buscaba reducir posibles aglomeraciones pero también significó que el pasajero no se viera en la obligación de validar el pago en cada una de las etapas de su viaje.

A lo anterior se suma el hecho de que las zonas pagas presentaron una reducción en el número de puntos operativos en los primeros meses de pandemia. Además, es posible notar que las zonas pagas, en general, disminuyen su funcionamiento durante el fin de semana, tal como se muestra en la tabla a continuación.

Tabla 4.4: Número de zonas pagas en operación, por tipo de día y corte temporal

Día	Marzo 2020	Mayo 2020	Julio 2020	Noviembre 2020	Julio 2021	Noviembre 2021
Laboral	244	122	130	176	181	177
Sábado	44	32	41	61	56	54
Domingo	13	12	12	12	11	12

Fuente: Elaboración Propia en base a DTP (2021)

Luego, ante la menor presencia de zonas pagas es probable que la evasión se haya visto favorecida, afectando la calidad y cantidad de información que se dispone del usuario de transporte público.

4.2. Análisis de viajes

Una segunda área de interés a analizar corresponde a la cantidad de viajes en transporte público realizados por los usuarios del sistema, en cada uno de los cortes temporales en estudio. Para ello, resulta útil recordar las definiciones de viaje y etapa.

Se entiende como etapa al tramo de viaje comprendido entre la subida y la bajada a un modo de transporte por parte de un usuario. Por otro lado, el viaje contempla el desplazamiento entre un origen y un destino (sitio donde realizará la actividad que motivó el viaje), pudiendo estar comprendido por una o más etapas de viaje dependiendo del número de trasbordos y/o cambios de modo que el usuario realice (Devillaine et al., 2012; Amaya, 2013).

En la tabla 4.5 que sigue se muestra el número de viajes efectuados en cada día de la semana, para los seis cortes temporales de marzo 2020, mayo 2020, julio 2020, noviembre 2020, julio 2021 y noviembre 2021. Adicionalmente, se indica entre paréntesis el número de etapas por viaje registradas para cada tipo de día.

Tabla 4.5: Total de viajes por día de la semana y corte temporal

Día	Marzo 2020	Mayo 2020	Julio 2020	Noviembre 2020	Julio 2021	Noviembre 2021
Lunes	3.180.191	478.459	578.842	1.636.151	1.941.176	2.456.592
Martes	3.266.510	455.613	472.807	1.616.440	1.938.400	2.467.215
Miércoles	3.041.739	446.437	552.650	1.643.934	1.959.174	2.505.211
Jueves	3.238.234	446.249	537.654	1.657.135	1.992.868	2.484.580
Viernes	3.224.357	476.329	568.055	1.740.356	2.113.944	2.542.853
Promedio Laboral	3.190.206 (1,35)	460.617 (1,33)	542.002 (1,34)	1.658.803 (1,35)	1.989.112 (1,35)	2.491.290 (1,33)
Sábado	1.657.023 (1,32)	279.953 (1,29)	327.499 (1,31)	1.053.365 (1,29)	1.302.204 (1,28)	1.541.824 (1,28)
Domingo	864.759 (1,33)	157.149 (1,28)	180.321 (1,31)	586.656 (1,29)	788.423 (1,27)	876.947 (1,27)
Total Semanal	18.472.813	2.740.189	3.217.828	9.934.037	12.036.189	14.875.222

Fuente: Elaboración Propia en base a ADATRAP

El número de etapas por viaje fluctúa entre 1,27 – 1,38 (etapas/viaje), siendo más alto durante los días laborales del corte temporal de marzo 2020, y más bajo en los fines de semana, específicamente el domingo de los cortes temporales de julio 2021 y noviembre 2021.

Por otro lado, se observa que el total de viajes sigue el comportamiento mostrado por las transacciones diarias, presentando una disminución del 86% en los comienzos de la pandemia respecto al número de viajes medidos en el día promedio laboral de marzo 2020. A la vez, es posible notar que a noviembre 2021 el número de viajes en día laboral sigue sin recuperar los niveles registrados antes de la crisis sanitaria (-22%).

Respecto a los viajes durante los fines de semana, la recuperación de la movilidad ha sido mayor que en los días laborales. En la tabla 4.5 se ve que, a noviembre 2021, el total de viajes del día tipo sábado se encuentran un 7% por debajo de la situación inicial. Por el contrario, para el día tipo domingo los viajes registrados en el corte temporal de noviembre 2021 superan al total de viajes existentes previo a la pandemia por COVID-19.

4.3. Análisis de tarjetas del sistema

Para estudiar el comportamiento de los usuarios del transporte público, vale la pena recordar que dentro de la información almacenada por el sistema no se encuentra la identidad del pasajero y no es posible diferenciar el tipo de tarjeta (adulto, escolar o adulto mayor). En efecto, cada transacción que se realiza mediante la validación de una tarjeta inteligente, ya sea a bordo del bus, en estaciones de metro y tren, o en zonas pagas, queda asociada en la base de datos al número identificador ID de dicha tarjeta Bip!.

El ID es un número único de cada tarjeta inteligente. No obstante, múltiples pasajeros pueden usar una misma tarjeta Bip!, o bien, un mismo usuario puede poseer más de una tarjeta y usarlas de forma frecuente. Es por ello que el análisis que se entrega en el presente acápite se centra en estudiar como varía temporalmente el comportamiento de las tarjetas existentes en el sistema.

En la tabla 4.6 se presenta el total de tarjetas utilizadas, para cada día de la semana y corte temporal. Paralelamente se señala entre paréntesis el número de viajes promedio por tarjeta, medido para cada tipo de día.

Tabla 4.6: Total de tarjetas por día de la semana y corte temporal

Día	Marzo 2020	Mayo 2020	Julio 2020	Noviembre 2020	Julio 2021	Noviembre 2021
Lunes	1.653.408	286.281	343.649	888.849	1.027.089	1.266.397
Martes	1.715.675	270.080	280.242	871.167	1.019.848	1.263.926
Miércoles	1.611.693	265.088	324.966	886.258	1.033.079	1.283.074
Jueves	1.669.718	264.493	316.927	893.406	1.049.260	1.278.155
Viernes	1.677.777	282.965	337.067	944.169	1.114.446	1.310.598
Promedio Laboral	1.665.654 (1,9)	273.781 (1,7)	320.570 (1,7)	896.770 (1,8)	1.048.744 (1,9)	1.280.430 (2,0)
Sábado	932.578 (1,8)	177.964 (1,6)	209.365 (1,6)	606.849 (1,7)	722.521 (1,8)	841.740 (1,8)
Domingo	532.641 (1,6)	105.965 (1,5)	122.231 (1,5)	364.121 (1,6)	464.410 (1,7)	516.208 (1,7)

Fuente: Elaboración Propia en base a ADATRAP

Se puede ver que el total de tarjetas activas en el sistema mostró una reducción del 84% en los inicios de la pandemia, respecto al día promedio laboral de marzo 2020. A la vez, se nota que a noviembre 2021 el total de tarjetas en día laboral no logró retomar los niveles existentes antes de la crisis sanitaria (-23%).


Sobre las tarjetas utilizadas durante los fines de semana, la recuperación de estas ha sido mayor que en los días laborales. En la tabla 4.6 se ve que, a noviembre 2021, el total de tarjetas presentes los días sábado y domingo son un 10% y 3% menores que las de la situación inicial. Por otro lado, se observa que el promedio de viajes por tarjeta difiere a lo largo de una semana representativa, siendo mayor durante los días laborales.

Respecto al cambio con el transcurso de la pandemia, en el corte temporal de marzo 2020 se registraron cerca de 2 viajes al día por tarjeta para el día laboral promedio, mientras que durante el fin de semana el valor rondaba los 1,6-1,8 (viajes-día/tarjeta). Estas cifras se redujeron en los primeros meses de emergencia sanitaria. Con el paso del tiempo, el número de viajes realizados por tarjeta al día se recuperó, superando incluso en el corte temporal de noviembre 2021 los niveles registrados en la situación inicial.

Complementando el análisis anterior, en la figura 4.4 se presenta la distribución del uso de tarjetas, agrupadas por la cantidad de viajes diarios realizados con ellas (1, 2, 3, 4, 5 o más), para cada tipo de día y corte temporal.

Se visualiza que en el día promedio laboral la moda es dos viajes por tarjeta, para cada corte temporal, mientras que el segundo valor más frecuente es el de 1 (viaje-día/tarjeta). Por otro lado, durante fines de semana la tendencia se invierte, obteniéndose una mayor proporción de tarjetas que se validan para viajar una vez por día.

Figura 4.4: Distribución del uso de tarjetas por cantidad de viajes diarios, tipo de día y corte temporal



Fuente: Elaboración Propia en base a ADATRAP


Para estudiar en mayor detalle los cambios en el comportamiento de uso de las tarjetas inteligentes durante la pandemia por COVID-19, se muestra en las figuras 4.5, 4.6 y 4.7 como se particionó el total de tarjetas en el número de viajes diarios, para cada corte temporal.

En primer lugar, se puede notar que la emergencia sanitaria ocasionó un incremento en la proporción de tarjetas que se usaron para realizar solo un viaje durante el día, en desmedro de las tarjetas con tres o más viajes por día, tanto en días laborales como en fines de semana. Esta situación puede esconder, en primer lugar, aumentos en la evasión al pago del pasaje, lo cual va en línea con la medida abordada por los operadores del sistema (ingreso de pasajeros por puerta trasera sin validar). Luego, la información recopilada queda incompleta y no se tiene conocimiento total de las cadenas de viajes de los usuarios.

También puede explicarse por el menor uso del transporte público ante el miedo de contagio, acompañado del aumento en las elecciones por el automóvil y la bicicleta. Lo anterior se reflejó en que los pasajeros que debieron seguir viajando en los inicios de la pandemia buscaron más alternativas para desplazarse. Con ello, parte de los viajes que antes realizaban tanto de ida como de regreso en transporte público, pasaron a ser combinados con otros modos no integrados. La información que se dispone no permite cuantificar el peso de cada causa posible.


En el corte temporal de noviembre 2021 las particiones observadas se asemejan bastante a las de la situación inicial, donde prácticamente la mitad de las tarjetas en día laboral se usan para dos viajes diario, mientras que durante el fin de semana el valor más frecuente es el de un viaje al día por tarjeta.

Figura 4.5: Proporción de tarjetas por cantidad de viajes diarios y corte temporal – laboral




Fuente: Elaboración Propia en base a ADATRAP

Figura 4.6: Proporción de tarjetas por cantidad de viajes diarios y corte temporal – sábado



Fuente: Elaboración Propia en base a ADATRAP

Figura 4.7: Proporción de tarjetas por cantidad de viajes diarios y corte temporal – domingo



Fuente: Elaboración Propia en base a ADATRAP

Por otro lado, con los datos disponibles es posible estudiar cuantas tarjetas diferentes se registraron en el sistema para cada corte temporal y obtener el número de días a la semana que la tarjeta realizó viajes. Con esto, se tiene una aproximación de la frecuencia con la que viajan en transporte público los pasajeros. En efecto, en la tabla 4.7 se sintetiza el total de tarjetas con distinto ID a la semana, el número de transacciones y viajes que en promedio cada tarjeta realiza semanalmente, y la media del número de días que se utilizó el sistema.

Tabla 4.7: Total de tarjetas diferentes en la semana por corte temporal

	Marzo 2020	Mayo 2020	Julio 2020	Noviembre 2020	Julio 2021	Noviembre 2021
Total de tarjetas diferentes	3.250.026	704.838 (-78%)	820.095 (-75%)	2.097.285 (-35%)	2.368.044 (-27%)	2.747.785 (-15%)
Transacciones a la semana por tarjeta	7,6	5,1	5,2	6,3	6,8	7,2
Viajes a la semana por tarjeta	5,7	3,9	3,9	4,7	5,1	5,4
Días a la semana que viaja	3,0	2,3	2,4	2,6	2,7	2,8

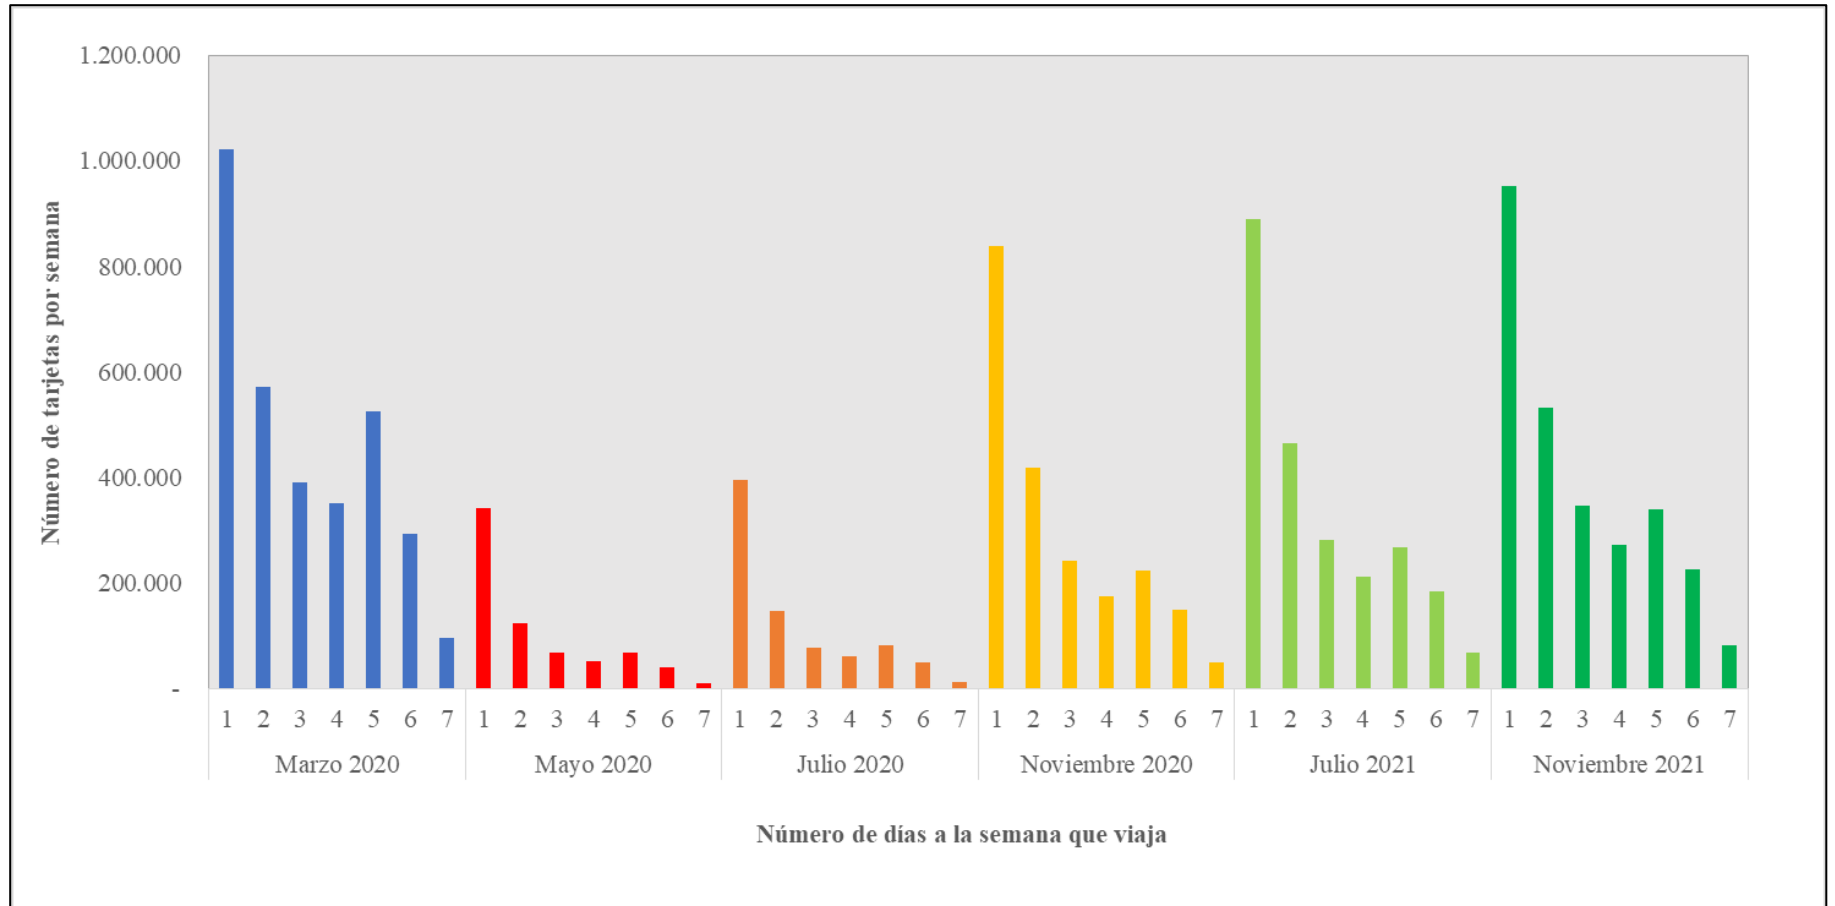
Fuente: Elaboración Propia en base a ADATRAP

Se puede ver que el total de tarjetas diferentes en el sistema disminuyó en los inicios de la pandemia (-78%), respecto al corte temporal de marzo 2020. A la vez, se nota que a noviembre 2021 el total de “usuarios” de transporte público sigue por debajo de los niveles existentes antes de la crisis sanitaria (-15%).

Con respecto al nivel de utilización de las tarjetas y la frecuencia con la que los usuarios del sistema viajan, la figura 4.8 muestra para cada corte temporal la distribución del número de tarjetas observadas según la cantidad de días a la semana que registraron viajes.

En términos generales se observa que la mayor cantidad de tarjetas se utiliza uno o dos días por semana. Respecto a la siguiente mayoría, es posible notar que antes de la crisis sanitaria correspondía a los usuarios que ocupaban la tarjeta en cinco días de la semana. Sin embargo, con el transcurso de la pandemia por COVID-19, la frecuencia decayó producto de las restricciones impuestas por la autoridad al desplazamiento, la implementación del teletrabajo en diversos rubros, el auge del e-commerce, entre otros.

Figura 4.8: Distribución del número de días a la semana con viajes por corte temporal



Fuente: Elaboración Propia en base a ADATRAP

Para complementar lo antes señalado, en la tabla 4.8 se aprecia el comportamiento en el tiempo de los usuarios frecuentes y esporádicos identificados, considerando como usuario frecuente a aquel que realiza viajes cuatro o más días de la semana, y esporádico a quien viaja un día de la semana en transporte público (Amaya, 2013). Entre paréntesis se indica la proporción de usuarios respecto al total de tarjetas con distinto ID registradas en la semana correspondiente.

Tabla 4.8: Total de usuarios por tipo y corte temporal, a partir de la frecuencia con la que viaja

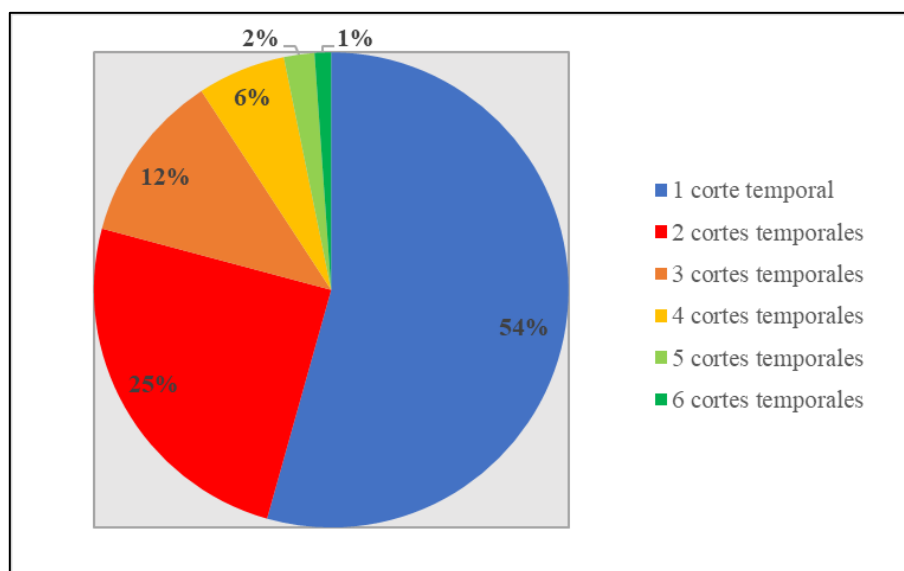
Tipo de usuario	Marzo 2020	Mayo 2020	Julio 2020	Noviembre 2020	Julio 2021	Noviembre 2021
Frecuente	1.264.500 (39%)	169.528 (24%)	200.226 (24%)	595.743 (28%)	731.072 (31%)	918.488 (33%)
Esporádico	1.023.141 (31%)	342.337 (49%)	395.135 (48%)	839.755 (40%)	889.778 (38%)	952.871 (35%)

Fuente: Elaboración Propia en base a ADATRAP

Al corte temporal de noviembre 2021, la presencia de usuarios frecuentes en el transporte público se mantiene por debajo de lo existente previo a la pandemia, mientras que los usuarios esporádicos han tomado mayor relevancia.

Finalmente, se estudia la periodicidad de los usuarios del sistema, es decir, se determina si las tarjetas aparecen en uno o más cortes temporales. En la figura 4.9 se muestra cómo se distribuye la permanencia de las tarjetas en el tiempo, de acuerdo con el número de cortes temporales en los que realiza algún viaje.

Figura 4.9: Distribución de tarjetas de acuerdo con el número de cortes temporales en los que aparece



Fuente: Elaboración Propia en base a ADATRAP

El total de tarjetas con diferentes ID observadas en alguno de los seis cortes temporales, sin repetición, es 6.642.867. Se puede ver que más de la mitad de las tarjetas (54%) se encuentra sólo en un corte temporal, donde un 20% de estas corresponde a tarjetas utilizadas únicamente en marzo 2020 que no vuelven aparecer en los registros, mientras que un 16% de ellas se usaron sólo en noviembre 2021.


Por otro lado, el 1,1% del total de tarjetas realizó viajes en transporte público en cada corte temporal analizado, mientras que un 2,7% aparece en los cortes temporales de marzo 2020, noviembre 2020, julio 2021 y noviembre 2021. Es decir, no se tuvo registro de dichas tarjetas en los cortes temporales representativos de los meses más críticos de la pandemia por COVID-19, pero reaparecieron a medida que se levantaron las restricciones de movilidad y la emergencia sanitaria se estabilizó gradualmente.

4.4. Análisis espacial a nivel comunal

A partir del cruce de los datos de transacciones en transporte público con los de posicionamiento, se obtiene información sobre la ubicación geográfica y hora de las validaciones registradas. Cabe recordar que en el caso de las transacciones realizadas en estaciones de metro, tren o zonas pagas, al ser sitios fijos la posición geográfica asignada a la validación corresponderá a la de la estación. A su vez, para las transacciones efectuadas al abordar los buses, se utiliza el posicionamiento GPS de estos y se sigue la metodología explicada en los capítulos 2 y 3.


En las siguientes figuras 4.10, 4.11 y 4.12 se muestra la distribución espacial de la demanda, a nivel comunal y por tipo de día. Para ello, se consideran todas las transacciones realizadas diariamente en los cortes temporales estudiados.

Figura 4.10: Distribución espacial de las transacciones por comuna y corte temporal - laboral



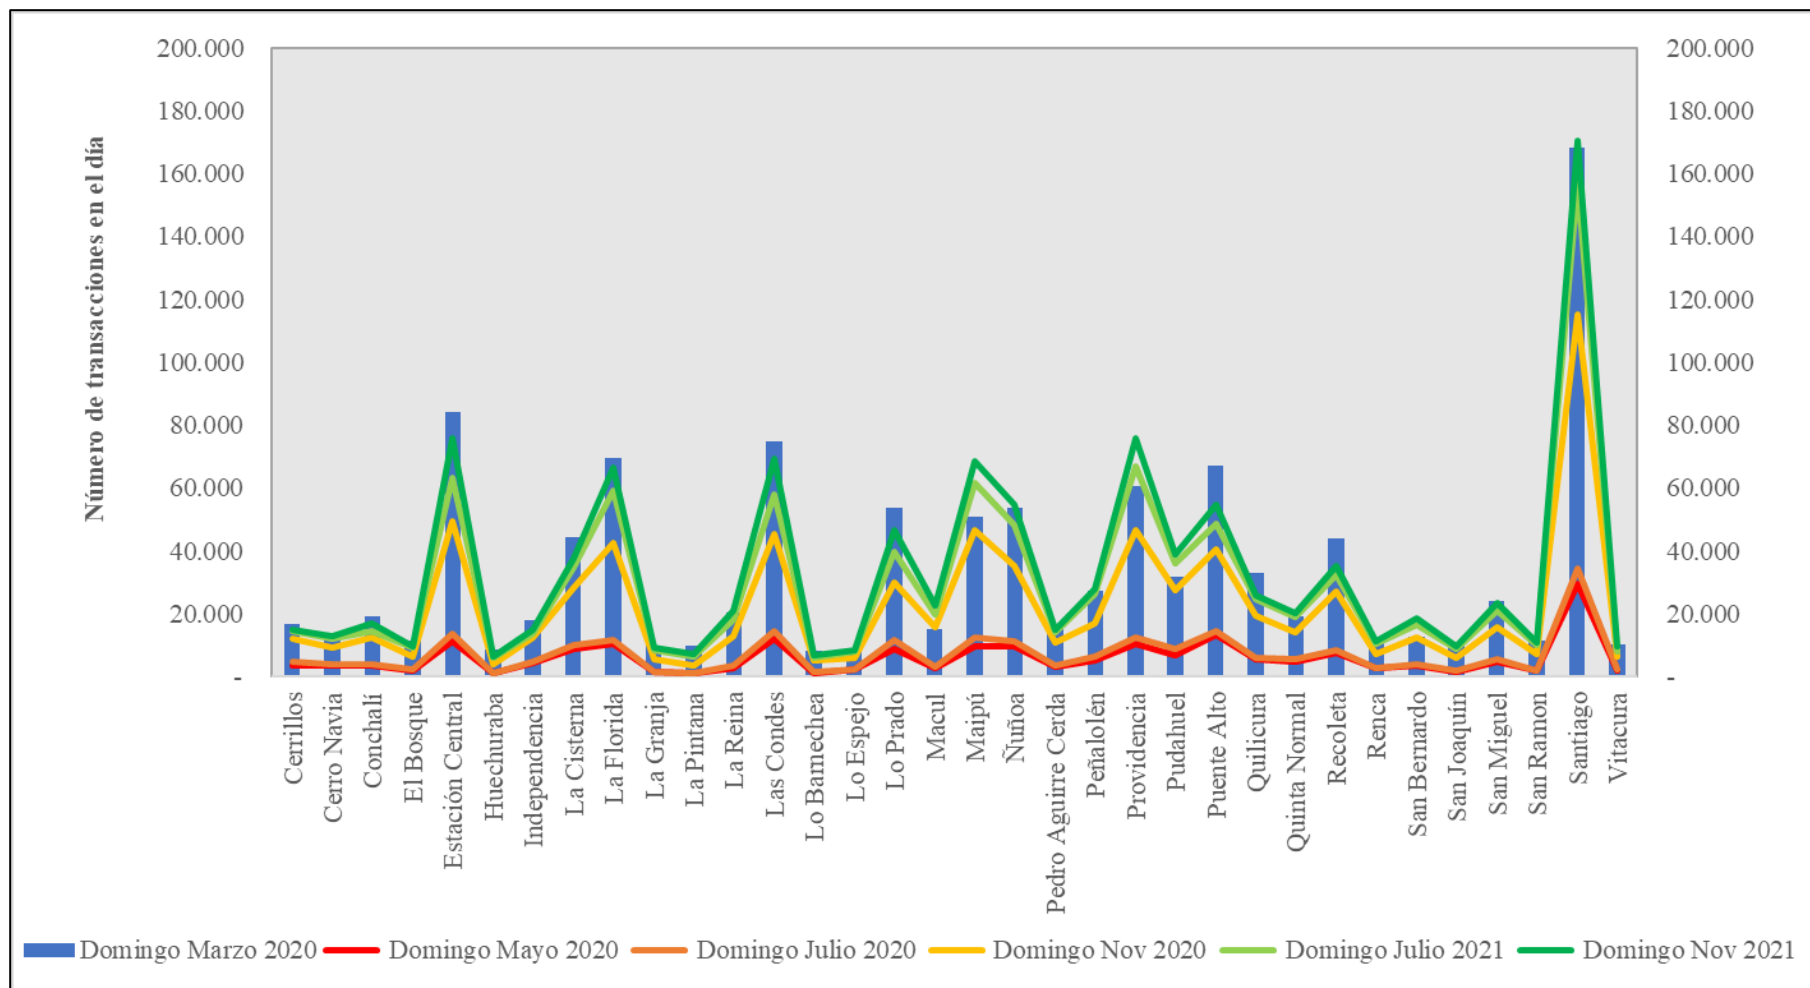
Fuente: Elaboración Propia en base a ADATRAP

Figura 4.11: Distribución espacial de las transacciones por comuna y corte temporal - sábado



Fuente: Elaboración Propia en base a ADATRAP

Figura 4.12: Distribución espacial de las transacciones por comuna y corte temporal - domingo



Fuente: Elaboración Propia en base a ADATRAP

Se observa que la comuna donde se efectúa la mayor cantidad de transacciones diarias en transporte público es la Santiago Centro, lo cual se condice con su alta densidad poblacional, actividad comercial y laboral. Si se comparan las validaciones que se realizaban antes de la pandemia respecto a las de noviembre 2021, se ve que el número de transacciones aún se encuentran por debajo de los niveles existentes para el día laboral promedio (-25%), mientras que para los días sábado y domingo la recuperación de la movilidad ha sido más rápida (-8% y +1% respectivamente).

Antes de la crisis sanitaria, otros sectores de la ciudad con una alta demanda en día laboral eran: Providencia, Las Condes, Ñuñoa en la zona oriente, Puente Alto y La Florida en la zona suroriente, Estación Central, Lo Prado y Maipú en la zona poniente, y Recoleta en la zona norte. A noviembre 2021, estos sectores, en general, no habían recuperado la cantidad de validaciones diarias. Se diferencia el caso de Maipú, donde incluso se superaron los niveles registrados previo a la pandemia (+21%).

Adicionalmente, se destacan las áreas de San Bernardo, Macul y Pudahuel, las cuales a pesar de generar menos transacciones que las comunas antes descritas, muestran una recuperación total a noviembre 2021, en cada tipo de día, incluso superando el total de validaciones registradas en la situación inicial.

Por el contrario, se identifican sectores donde las validaciones en transporte público presentan una caída permanente en comparación con lo observado previo a la pandemia por COVID-19. Comunas como Huechuraba, Recoleta, Independencia y Conchalí en la zona norte, Puente Alto en la zona sur, Cerrillos y Lo Prado en la zona poniente, Las Condes y Lo Barnechea en la zona oriente, y La Pintana en la zona sur, no recuperaron la cantidad de transacciones a noviembre 2021, en ninguno de los días tipo analizados. Los casos más críticos se perciben en las comunas de Huechuraba y La Pintana, las cuales presentan entre un 25%-40% menos de validaciones.

Es importante mencionar que el porcentaje de transacciones cuya posición geográfica se logra identificar exitosamente, se encuentra en torno al 98%-99% para el corte temporal de marzo 2020. Por otro lado, en los cortes temporales restantes, representativos de la situación con pandemia, la tasa de éxito supera el 99,5%.

Si bien el análisis a nivel comunal es bastante agregado para utilizar los resultados obtenidos como herramientas de planificación, entrega una primera aproximación del comportamiento espacial de los datos estudiados y permite caracterizarlos de forma más fácil e intuitiva.

4.5. Análisis espacial a partir de estimación de zona de residencia

Como se ha señalado anteriormente, las bases de datos de transacciones en transporte público no entregan información que permita identificar a los usuarios del sistema, y solo se cuenta con el ID de la tarjeta inteligente con la que se realiza la validación, el cual es anónimo.

El desconocer la identidad de los pasajeros implica que no es posible contar con información complementaria del viaje, como por ejemplo, las características sociodemográficas del dueño de la tarjeta. Esto impide analizar el comportamiento de los usuarios desde otra perspectiva. Es por ello que la estimación de la zona de residencia de los usuarios de transporte público es una herramienta que permite, bajo una serie de supuestos, incorporar nueva información a los datos de transacciones Bip!.

Basado en la metodología propuesta por Amaya (2018), descrita en el capítulo 2, se imputó la zona de residencia a todos los usuarios (tarjetas) que realizaron su primera validación entre las 04:00 y las 12:00 horas, de un día laboral. Esto asume que las personas pernoctan en su hogar y por ende, la primera transacción que efectúan en el día ocurre en una ubicación cercana a su residencia.

Por simplicidad, la zona imputada corresponderá a la comuna o distrito censal, en función del nivel de desagregación que se requiera analizar, donde se registró esa primera validación. Luego, al conocer las características sociodemográficas (población, ingreso, tasa de motorización, nivel educacional, etc.) que describen a cada área de la ciudad de Santiago, será posible asignar estos mismos atributos a los usuarios del sistema, considerando la ubicación estimada del hogar.

En el siguiente cuadro se resume el total de tarjetas diarias que cumple con la condición señalada anteriormente, es decir, realizan su primera transacción del día entre las 04:00-12:00 horas. A su vez, se indica entre paréntesis a que proporción corresponden respecto del total de tarjetas registradas en el día.

Tabla 4.9: Total de tarjetas con zona de residencia imputada, por día de la semana y corte temporal

Día	Marzo 2020	Mayo 2020	Julio 2020	Noviembre 2020	Julio 2021	Noviembre 2021
Lunes	1.142.402 (69%)	200.121 (70%)	236.249 (69%)	598.374 (67%)	687.037 (67%)	860.294 (68%)
Martes	1.173.197 (68%)	193.538 (72%)	201.458 (72%)	595.187 (68%)	685.375 (67%)	866.039 (69%)
Miércoles	1.152.365 (72%)	190.051 (72%)	224.992 (69%)	600.371 (68%)	689.910 (67%)	864.563 (67%)
Jueves	1.147.561 (69%)	187.771 (71%)	219.045 (69%)	600.369 (67%)	696.389 (66%)	863.204 (68%)
Viernes	1.129.073 (67%)	194.362 (69%)	226.135 (67%)	602.264 (64%)	695.249 (62%)	837.724 (64%)
Promedio Laboral	1.148.920 (69%)	193.169 (71%)	221.576 (69%)	599.313 (67%)	690.792 (66%)	858.365 (67%)

Fuente: Elaboración Propia en base a ADATRAP

Se observa que, en promedio, para cerca del 70% de las tarjetas usadas diariamente fue factible estimar la zona en que se localiza su hogar. Se nota también que esta proporción tiende a ser menor el viernes de cada semana analizada.

Por otro lado, al comparar el número de tarjetas que se utilizaban en las mañanas previas a la pandemia respecto a las de noviembre 2021, se evidencia una caída de aproximadamente un 25%. en el día laboral promedio. Esto se explica principalmente por la disminución en el número de usuarios que a diario ocupan el transporte público. Como se ha mencionado anteriormente, puede deberse a personas que cambiaron su modo de transporte, que redujeron sus viajes a la semana por motivo de teletrabajo, incluso pueden haber modificado el horario o el propósito por el cual usaban transporte público.

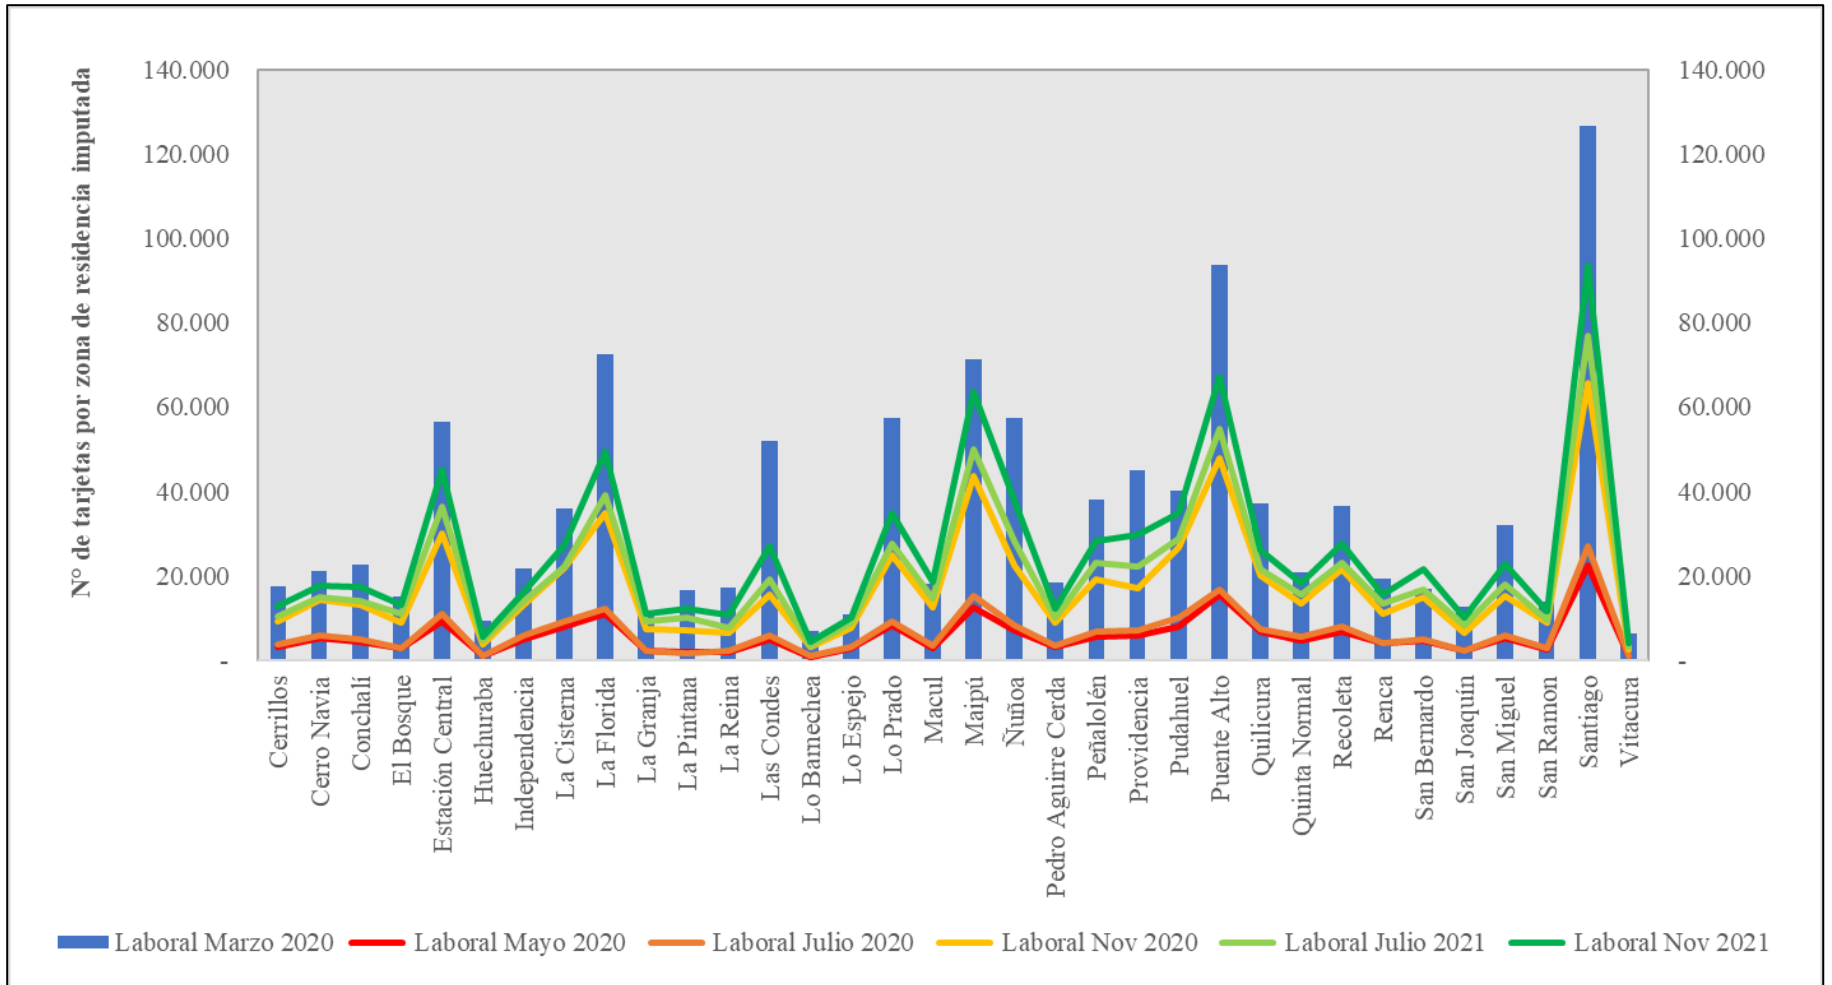
En la figura 4.13 se presenta la distribución espacial de aquella primera validación del día realizada durante la mañana. Para ello, se identifica la ubicación de la transacción, se imputa su zona de residencia y posteriormente, se agrupan las tarjetas por comuna asignada, para cada corte temporal estudiado.

Dentro de las comunas que mostraban antes de la crisis sanitaria un mayor número de tarjetas con su primera validación del día en la mañana se encuentran: Santiago Centro, Puente Alto, La Florida, Las Condes, Ñuñoa, Estación Central, Lo Prado y Maipú. Estos sectores, no recuperaron la cantidad de usuarios matutinos, siendo los casos más críticos Las Condes (-48%) y Lo Prado (-39%).

Por el contrario, se destacan las áreas de San Bernardo (+27%) y Macul (+2%) como las únicas que tienen una recuperación total a noviembre 2021, incluso superando el total de tarjetas registradas en la situación inicial.

En el siguiente capítulo se aplicará la metodología de imputación de zona de residencia sobre tarjetas con su primera transacción del día en la mañana, desagregando a nivel de distrito censal, para estudiar los factores que pueden impactar en la no recuperación total de los usuarios de transporte público.

Figura 4.13: Distribución espacial de las tarjetas con su primera validación del día en la mañana, agrupadas por comuna y corte temporal - laboral



Fuente: Elaboración Propia en base a ADATRAP

Capítulo 5: Análisis en base a Modelos de Regresión Lineal

El presente capítulo tiene como finalidad entregar los resultados obtenidos de las estimaciones de modelos de regresión lineal múltiple y de regresión espacial, los cuales buscan determinar cuáles de las variables descritas explican la recuperación de la movilidad de los usuarios del transporte público en la mañana producto de la pandemia por COVID-19.

En primer lugar, se construyen y caracterizan la variable explicada y las variables independientes utilizadas en la modelación del fenómeno. Posteriormente, se presentan hipótesis sobre la influencia de cada variable explicativa propuesta en el número de viajes, basado en la literatura previa revisada y consideraciones.

Luego, se estiman los modelos y se obtienen los coeficientes de cada variable incluida. Para ello se utilizan los softwares SPSS y Stata, los cuales permiten realizar diversos análisis estadísticos avanzados en grandes bases de datos de manera sencilla. La teoría que sustente a los modelos de regresión lineal múltiple y regresión espacial se encuentra en el Capítulo 2.

Cabe señalar que la calidad, insesgamiento y eficiencia de los parámetros estimados dependen del cumplimiento de los supuestos de regresión multivariada. Se presenta, en una primera instancia, los resultados de los modelos mediante la técnica de mínimos cuadrados ordinarios (MCO).

A su vez, se realizan test para verificar el cumplimiento de supuestos requeridos, específicamente para detectar la presencia de autocorrelación espacial. Se entregan nuevas estimaciones a partir de modelos que corrigen la correlación identificada y se realiza un análisis comparativo respecto a los estimadores obtenidos en la configuración con MCO.

Finalmente, se estudian los signos de los coeficientes estimados y la significancia estadística, así como también se discute la validez de los modelos propuestos, la bondad del ajuste y la importancia relativa de las variables explicativas sobre el fenómeno estudiado.

5.1. Construcción de variables

5.1.1. Variable explicada

Para representar la recuperación de la movilidad de los usuarios del transporte público en la mañana, en cada corte temporal t y distrito censal i analizado, se utilizará el indicador $Rec_{pm1,t,i}$, que se describe en la siguiente expresión.

$$Rec_{pm1,t,i} = \frac{\text{Nº Usuarios con su primer viaje del día en la mañana, desde el distrito } i, \text{ en el corte temporal } t}{\text{Nº Usuarios con su primer viaje del día en la mañana, desde el distrito } i, \text{ en marzo 2020}} \quad (5.1)$$

Este compara cómo varía en el transcurso de la pandemia el número de usuarios de transporte público que realizan su primera validación del día en la mañana (entre las 04:00 y 12:00 horas, con origen del viaje en la zona de residencia ubicada en el distrito censal i). Por lo tanto, el indicador contrasta, para cada distrito censal i , una situación inicial (prepandemia, Marzo 2020) con una situación que refleja un momento de la pandemia por COVID-19 (corte temporal t , Mayo 2020, Julio 2020, Noviembre 2020, Julio 2021 o Noviembre 2021).

Notar que, si el indicador toma valores entre 0% y 100%, significa que en el corte temporal analizado se observaron menos usuarios de transporte público viajando en la mañana, en comparación con los existentes en la situación inicial, previa a la pandemia por COVID-19. A su vez, si el indicador toma valores mayores al 100%, significa que en la situación con pandemia ya se recuperaron y superaron los niveles de usuarios del transporte público en la mañana medidos antes de la crisis sanitaria.

Para estimar la variable explicada se consideraron cinco cortes temporales, cada uno representado por un día laboral tipo, los cuales se compararon con el corte temporal de referencia de marzo 2020. Específicamente, se usaron los datos de transacciones en transporte público de marzo, mayo, julio y noviembre 2020, julio y noviembre 2021, los cuales fueron descritos en los capítulos 3 y 4.

Por otro lado, se ha incluido en el análisis, inicialmente, un total de 345 distritos censales, todos localizados en la ciudad de Santiago de Chile. En la figura 5.1 a continuación se identifica la ubicación de las comunas existentes en Santiago y se observa su desagregación por distrito censal.

Adicionalmente, en la tabla 5.1 se exponen estadísticos descriptivos iniciales del indicador estudiado, para cada corte temporal. En ella se observa que la recuperación de la movilidad de los usuarios del transporte público en la mañana fue incrementándose con el desarrollo de la pandemia. Sin embargo, la media se encuentra por debajo del 100% en cada corte temporal, es decir, a fines del año 2021, en promedio, aún no se lograba alcanzar los niveles existentes previo a la crisis sanitaria por COVID-19.

Figura 5.1: Representación de los distritos censales y su división comunal



Fuente: Elaboración Propia

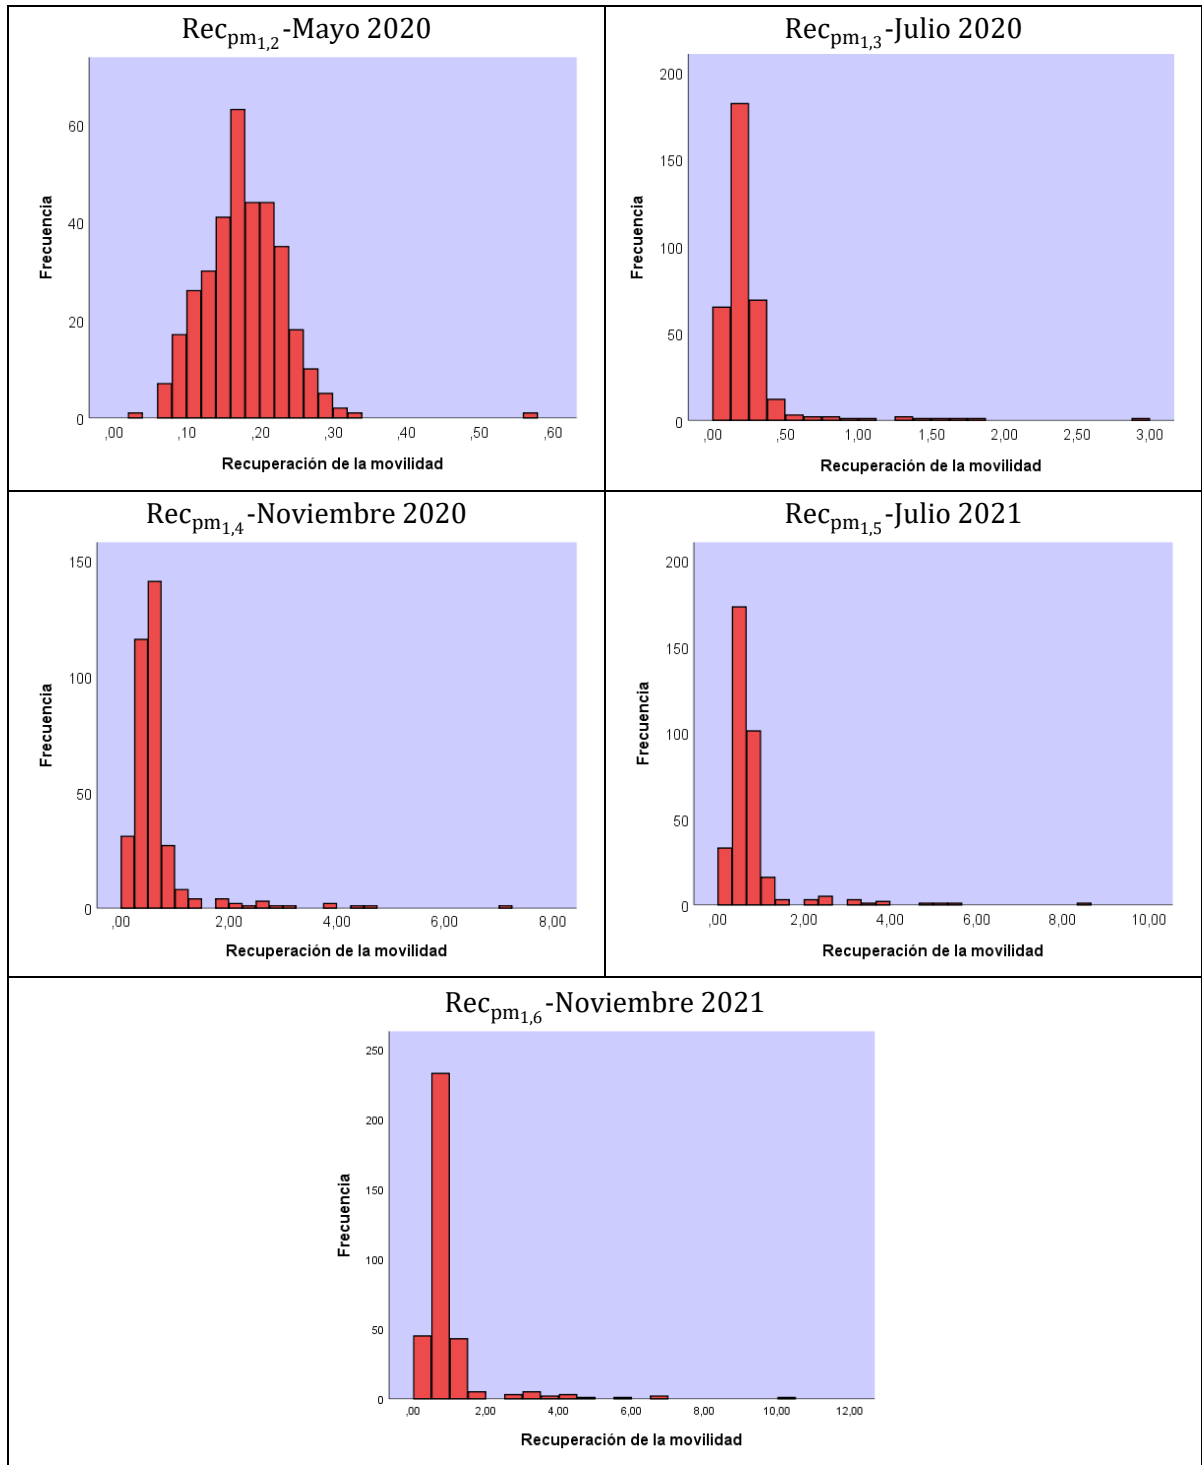
Tabla 5.1: Estadísticos descriptivos iniciales del indicador de recuperación movilidad de usuarios del transporte público en la mañana

Variable dependiente	Corte Temporal	Unidad	N° Obs.	Media	Máx	Min	Desv
Rec _{pm1,2}	Mayo 2020	(%)	345	17%	57%	3%	6%
Rec _{pm1,3}	Julio 2020	(%)	345	24%	289%	1%	25%
Rec _{pm1,4}	Noviembre 2020	(%)	345	65%	700%	5%	65%
Rec _{pm1,5}	Julio 2021	(%)	345	77%	834%	6%	78%
Rec _{pm1,6}	Noviembre 2021	(%)	345	94%	1049%	8%	96%

Fuente: Elaboración Propia

Para comprender más en detalle el comportamiento de la variable dependiente antes planteada y observar su distribución, a continuación, se muestran histogramas de frecuencia para cada corte temporal.

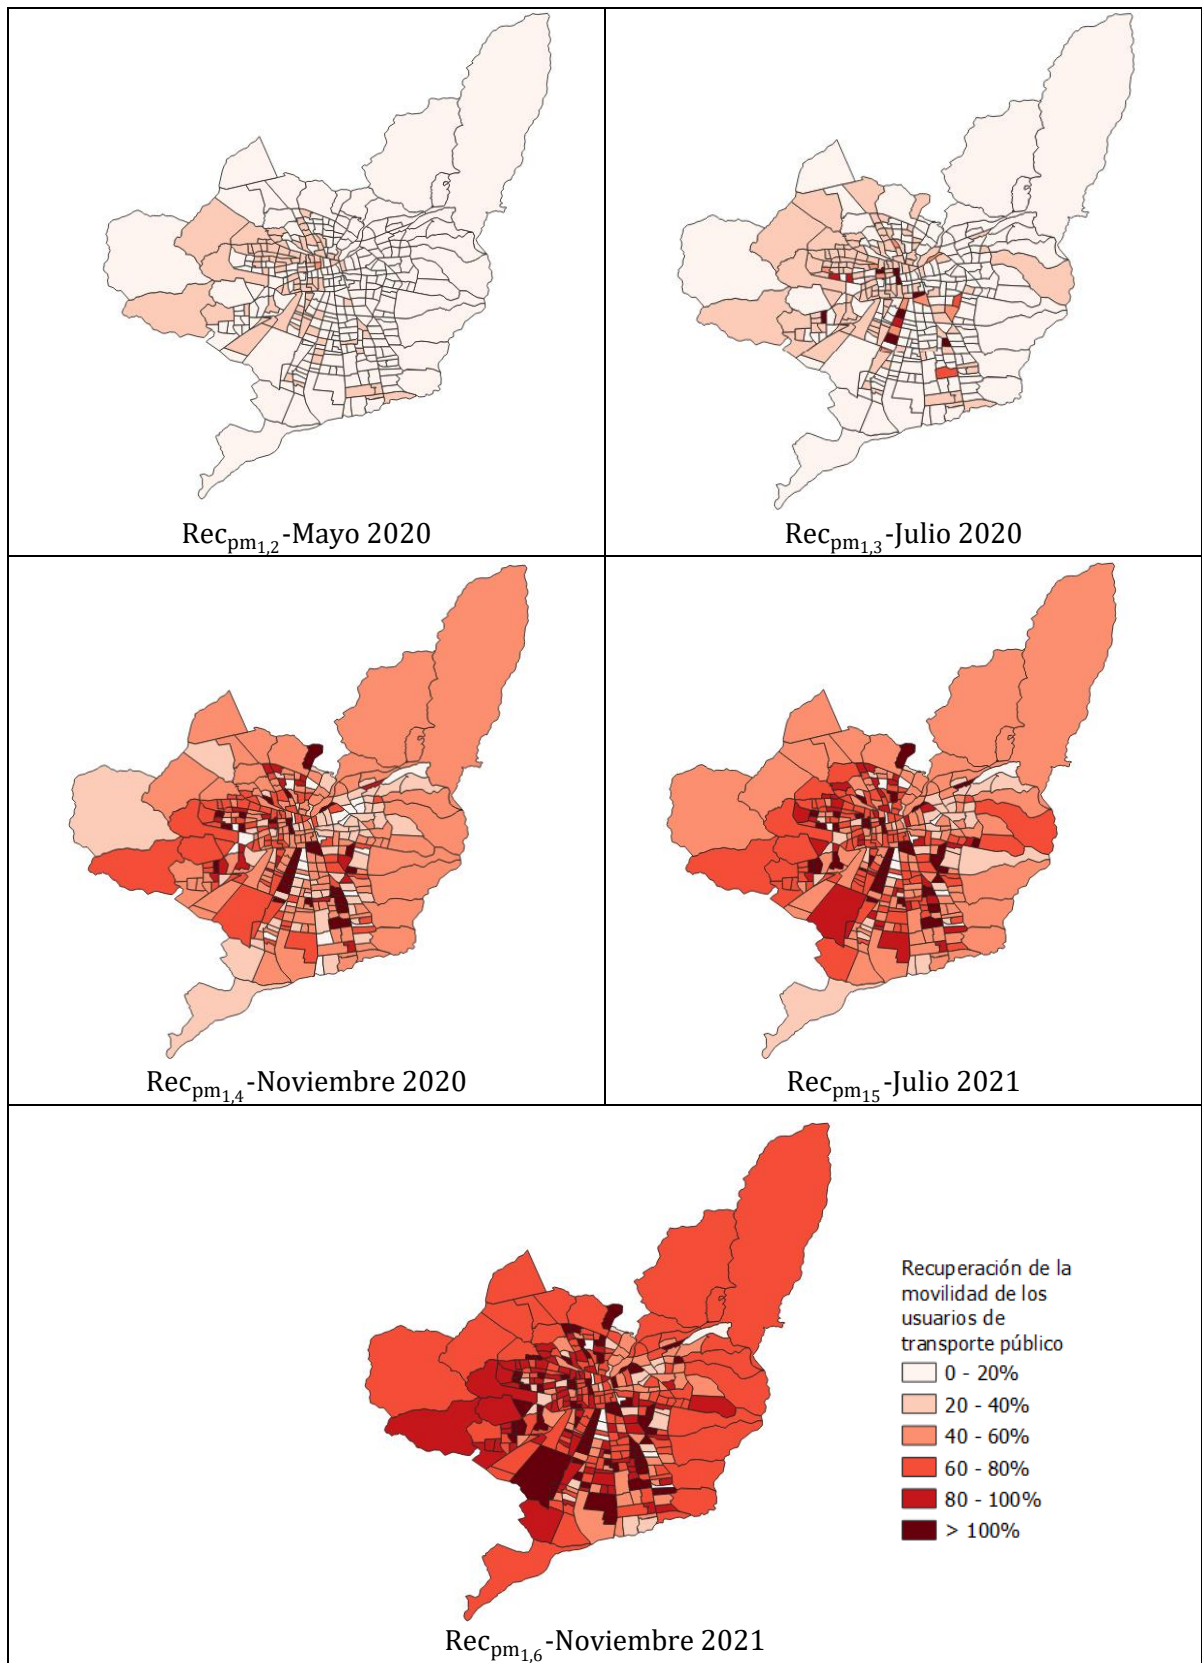
Figura 5.2: Histogramas de la variable dependiente, por corte temporal



Fuente: Elaboración Propia

A su vez, en la siguiente figura se presenta el comportamiento de la variable explicada y como esta cambia para cada área geográfica estudiada, en el transcurso de la pandemia. Tanto en los histogramas anteriores como en las figuras que siguen es posible notar la existencia de observaciones extremas.

Figura 5.3: Comportamiento espacial y evolución temporal de la recuperación de la movilidad de los usuarios del transporte público en la mañana



Fuente: Elaboración Propia

Por lo tanto, se han excluido del análisis aquellas observaciones más extremas, obteniéndose finalmente los siguientes estadísticos descriptivos del indicador estudiado, para cada corte temporal.

Tabla 5.2: Estadísticos descriptivos finales del indicador de recuperación movilidad de usuarios del transporte público en la mañana

Variable dependiente	Corte Temporal	Unidad	N° Obs.	Media	Máx	Min	Desv
Rec _{pm1,2}	Mayo 2020	(%)	344	17%	32%	3%	5%
Rec _{pm1,3}	Julio 2020	(%)	336	21%	89%	1%	12%
Rec _{pm1,4}	Noviembre 2020	(%)	340	60%	375%	5%	44%
Rec _{pm1,5}	Julio 2021	(%)	340	71%	399%	6%	52%
Rec _{pm1,6}	Noviembre 2021	(%)	340	87%	486%	8%	63%

Fuente: Elaboración Propia

5.1.2. Variables explicativas

Las variables consideradas para explicar la recuperación de la movilidad de los usuarios del transporte público en la mañana se agrupan en cinco categorías. En primer lugar, se presentan variables sociodemográficas, que entregan características de la población de cada distrito censal. Posteriormente, se exponen variables asociadas a las cuarentenas que se efectuaron en el transcurso de la pandemia. Luego, se incorporan variables relativas a la presencia de estudiantes en las áreas geográficas analizada. También se incluyen variables que buscan representar la accesibilidad al transporte. Finalmente, se contemplan variables que reflejan la existencia de trabajadores de ciertos rubros y/o sectores económicos en el distrito estudiado.

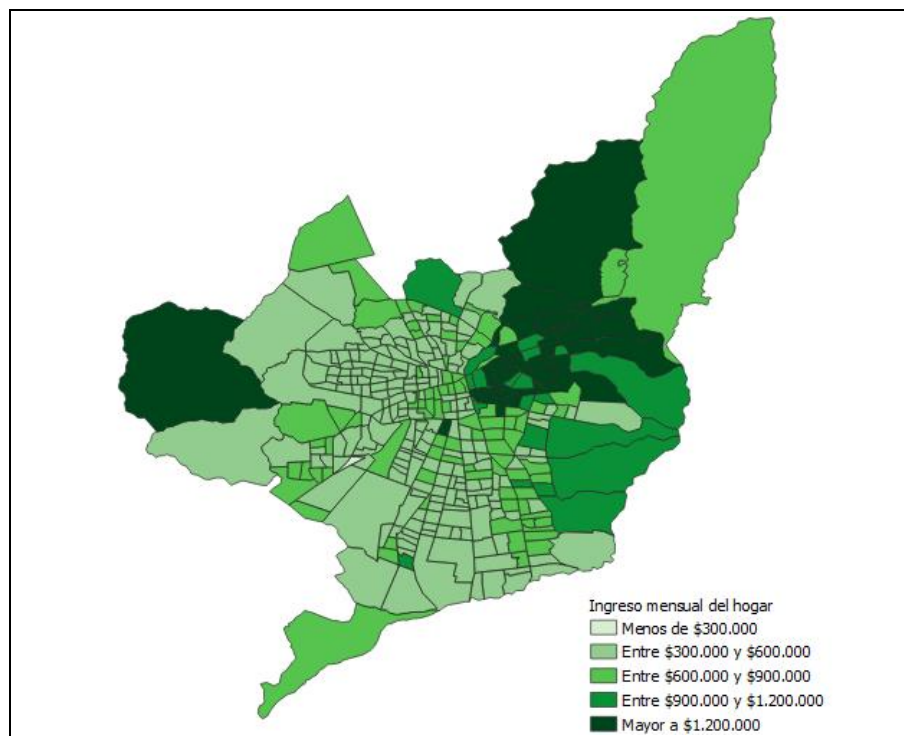
5.1.2.1. Variables explicativas: Sociodemográficas

Con la finalidad de caracterizar e identificar los atributos sociodemográficos de la población que pudiesen afectar en la recuperación de la movilidad de los usuarios del transporte público en la mañana, se incluyen las variables que se describen a continuación.

Cabe señalar que los atributos propuestos entregan características de un hogar tipo que se localiza en cierto distrito censal de la ciudad. Por tanto, se imputa a cada área un valor promedio que puede no ser representativo de los hogares que allí se ubican, limitando el análisis. Por otro lado, recordar que para asignar información sociodemográfica a los usuarios del transporte público se realizó una estimación de la zona de residencia, basado en una serie de supuestos, como considerar el origen de la primera transacción realizada durante la mañana. Luego, aquellos pasajeros que viajan desde su hogar en otros periodos del día no son incluidos en el análisis. Por su parte, para los usuarios que no pernoctan en su residencia y viajan en la mañana la imputación de atributos sociodemográficos podría ser errónea.

- *Nivel de ingreso promedio líquido mensual por hogar:* A partir de la información recogida en la EOD del año 2012 realizada por el Ministerio de Transporte y Telecomunicaciones (MTT), se determinó el ingreso promedio líquido de un hogar perteneciente a cada distrito censal, lo cual se representa en la figura a continuación.

Figura 5.4: Distribución espacial del ingreso promedio líquido mensual por hogar



Fuente: Elaboración Propia en base a MTT (2012)

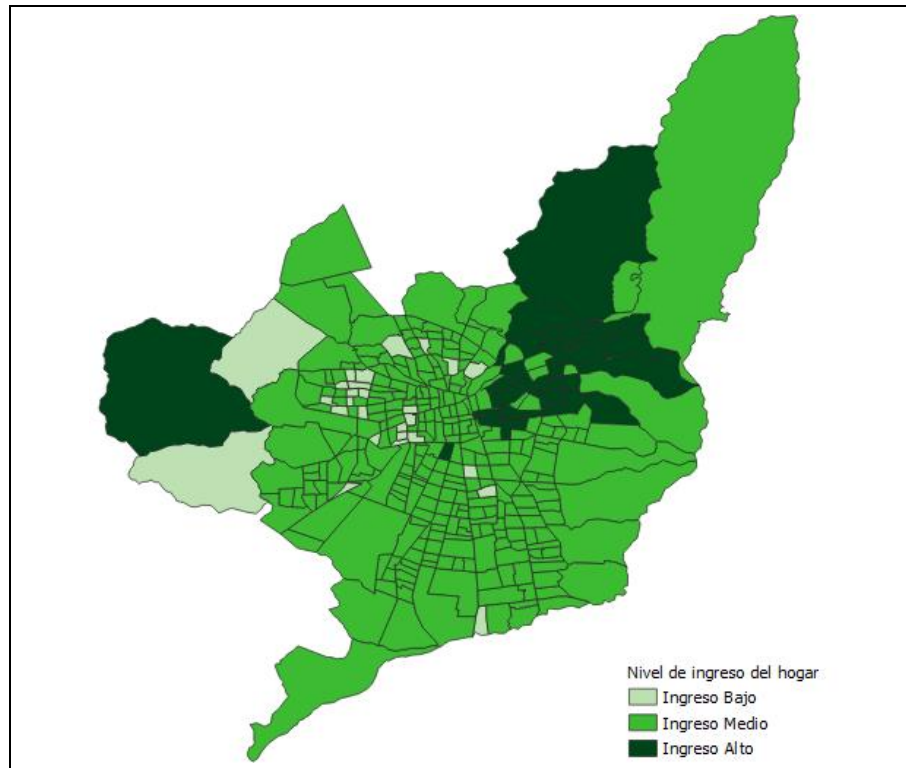
Luego, se imputó un nivel de ingreso (bajo, medio o alto) a cada distrito censal, de acuerdo con los siguientes rangos.

Tabla 5.3: Definición del nivel de ingreso a partir del ingreso promedio líquido mensual por hogar

Ingreso Promedio Mensual por Hogar	Nivel de Ingreso
Menor a \$400.000	Bajo
Entre \$400.000 y \$1.200.000	Medio
Mayor a \$1.200.000	Alto

Fuente: Elaboración Propia en base a MTT (2012)

Figura 5.5: Distribución espacial del nivel de ingreso por hogar



Fuente: Elaboración Propia en base a MTT (2012)

Producto de lo anterior, se definieron tres variables binarias, una por cada nivel de ingreso, las cuales toman valor uno si el distrito censal posee un nivel de ingreso bajo, medio o alto, según sea el caso, y cero en caso contrario, tal como se muestra en las siguientes ecuaciones.

$$\delta_{\text{ing bajo}} = \begin{cases} 1 & \text{si el distrito censal posee un nivel de ingreso por hogar bajo} \\ 0 & \text{en caso contrario} \end{cases} \quad (5.2)$$

$$\delta_{\text{ing medio}} = \begin{cases} 1 & \text{si el distrito censal posee un nivel de ingreso por hogar medio} \\ 0 & \text{en caso contrario} \end{cases} \quad (5.3)$$

$$\delta_{\text{ing alto}} = \begin{cases} 1 & \text{si el distrito censal posee un nivel de ingreso por hogar alto} \\ 0 & \text{en caso contrario} \end{cases} \quad (5.4)$$

El porcentaje de veces que cada variable de tipo dummy toma valor uno se detalla en la tabla a continuación. Se puede observar que, de acuerdo con la data disponible y la clasificación establecida, la mayoría de las áreas geográficas estudiadas se encuentran en el rango medio de nivel de ingreso por hogar.

Tabla 5.4: Descripción variable de tipo dummy asociada al nivel de ingreso promedio mensual por hogar

Nivel de Ingreso por Hogar	$\delta_{\text{ing bajo}}$		$\delta_{\text{ing medio}}$		$\delta_{\text{ing alto}}$	
	Frecuencia	Porcentaje	Frecuencia	Porcentaje	Frecuencia	Porcentaje
0	317	92%	60	17%	311	90%
1	27	8%	284	83%	33	10%
N° Observaciones	344					

Fuente: Elaboración Propia en base a MTT (2012)

Con el fin de evitar la existencia de multicolinealidad perfecta entre las variables ficticias, la dummy asociada al nivel de ingreso medio quedará fija, tomando valor cero para todo distrito censal. Por lo tanto, los coeficientes beta obtenidos al estimar modelos que incluyan estas variables dummy serán interpretados como la diferencia en la recuperación de la movilidad de los usuarios del transporte público en la mañana, entre zonas con nivel de ingreso medio y áreas con nivel de ingreso alto o bajo, según corresponda.

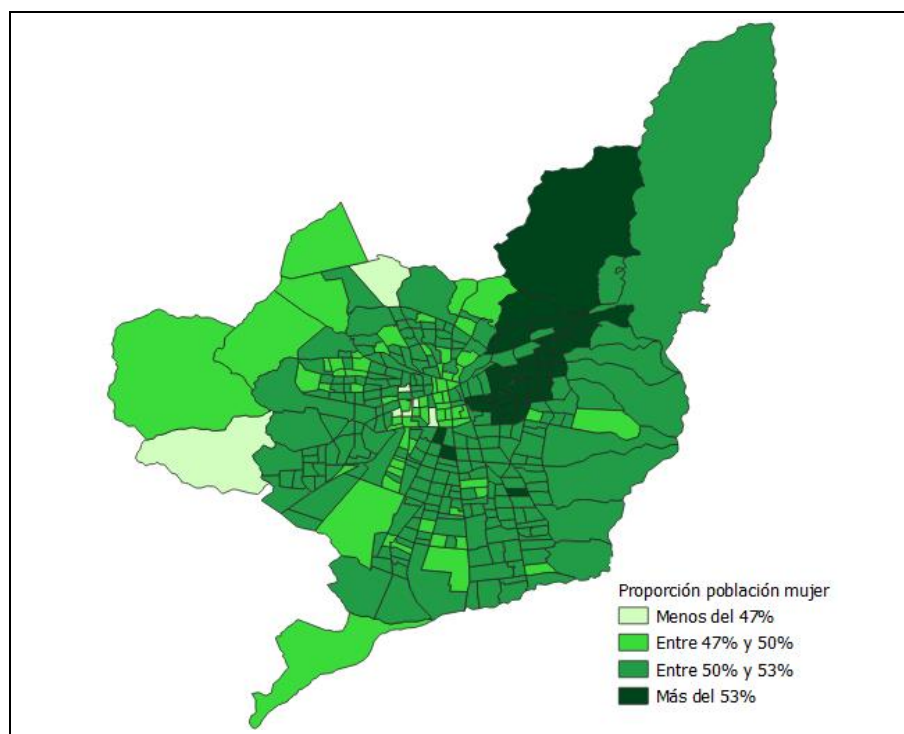
Se espera que sectores de la ciudad con nivel de ingreso alto presenten una recuperación más lenta, ya que, por lo general, tienen mayor acceso al automóvil, disponen de más alternativas para reemplazar el uso del transporte público y pueden pagar por ellas, trabajan en rubros donde se facilitó el teletrabajo o bien se instauró cierta flexibilidad horaria, entre otros.

Por otro lado, se espera que los distritos censales con nivel de ingreso bajo posean una recuperación de la movilidad mayor. Este se debe a que los usuarios de transporte público con menores ingresos suelen ser cautivos del sistema de transporte público, no pueden pagar otros modos de transporte y trabajan en rubros donde se requiere una mayor presencialidad, es decir, el teletrabajo no fue una opción sostenible en el tiempo.

- *Distribución porcentual por género de la población:* Variable explicativa que representa la proporción de mujeres que habitan en el distrito censal, de acuerdo con los antecedentes recogidos en el CENSO del año 2017 realizado por el Instituto Nacional de Estadísticas (INE). Se define a partir de la siguiente expresión.

$$\text{Muj} = \frac{\text{N}^\circ \text{ Mujeres que habitan en el distrito censal}}{\text{Población total del distrito censal}} \quad (5.5)$$

Figura 5.6: Distribución espacial de la proporción de mujeres



Fuente: Elaboración Propia en INE (2017)

En la tabla a continuación se presentan los estadísticos descriptivos obtenidos para la variable.

Tabla 5.5: Estadísticos descriptivos de la proporción por género de la población

Variables explicativas	Unidad	Media	Máx	Mín	Desv
Muj	(%)	51%	56%	9%	3%
N° Observaciones		345			

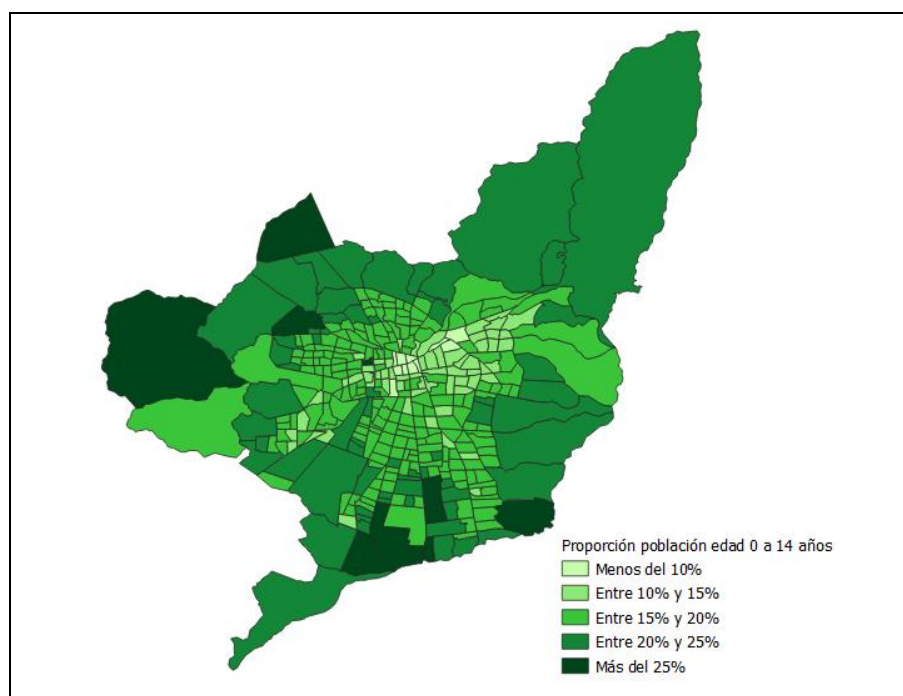
Fuente: INE (2017)

- *Distribución porcentual por grupos etarios de la población:* Variables independientes que representan como se distribuye la población del distrito censal en diversos rangos etarios (INE, 2017). Para ello, se establecieron los siguientes cuatro grupos.

- Proporción de la población con edad entre 0 y 14 años (niños).

$$\text{Edad}_{0-14} = \frac{\text{Población con edad entre 0 y 14 años en el distrito censal}}{\text{Población total del distrito censal}} \quad (5.6)$$

Figura 5.7: Distribución espacial de la proporción de la población con edad entre 0 y 14 años



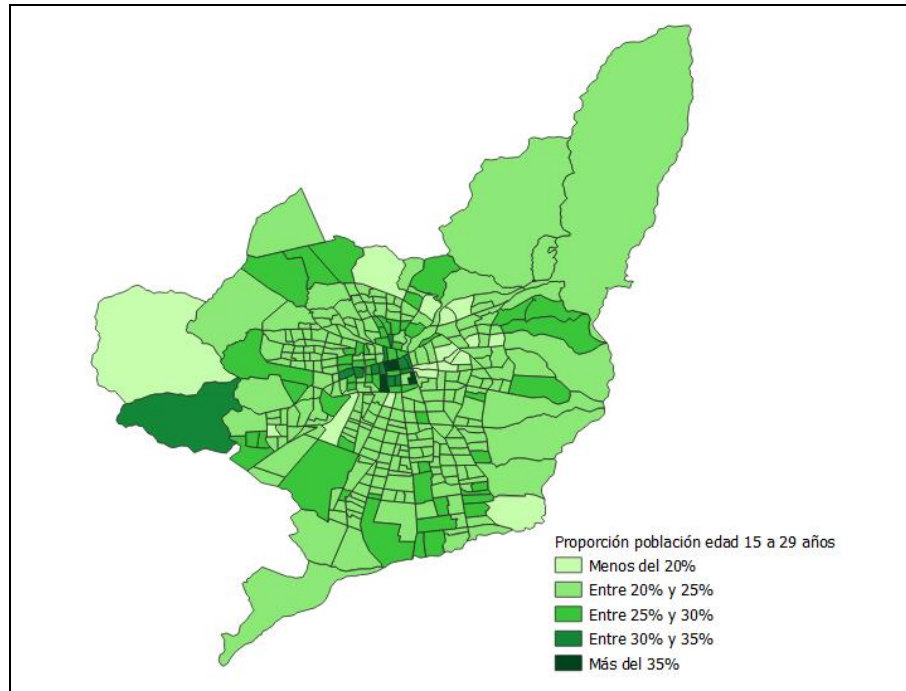
Fuente: Elaboración Propia en INE (2017)

Se espera que las zonas con mayor presencia de niños tengan una menor recuperación de la movilidad en transporte público. Esto va en línea con las medidas tomadas por la autoridad en el desarrollo de la pandemia por COVID-19, las restricciones impuestas al desplazamiento, el cierre de establecimientos que imparten educación parvularia y básica en el año 2020, la realización de clases en formato no presencial y el retorno gradual a las actividades a fines del año 2021, entre otros.

- Proporción de la población con edad entre 15 y 29 años (jóvenes).

$$\text{Edad}_{15-29} = \frac{\text{Población con edad entre 15 y 29 años en el distrito censal}}{\text{Población total del distrito censal}} \quad (5.7)$$

Figura 5.8: Distribución espacial de la proporción de la población con edad entre 15 y 29 años



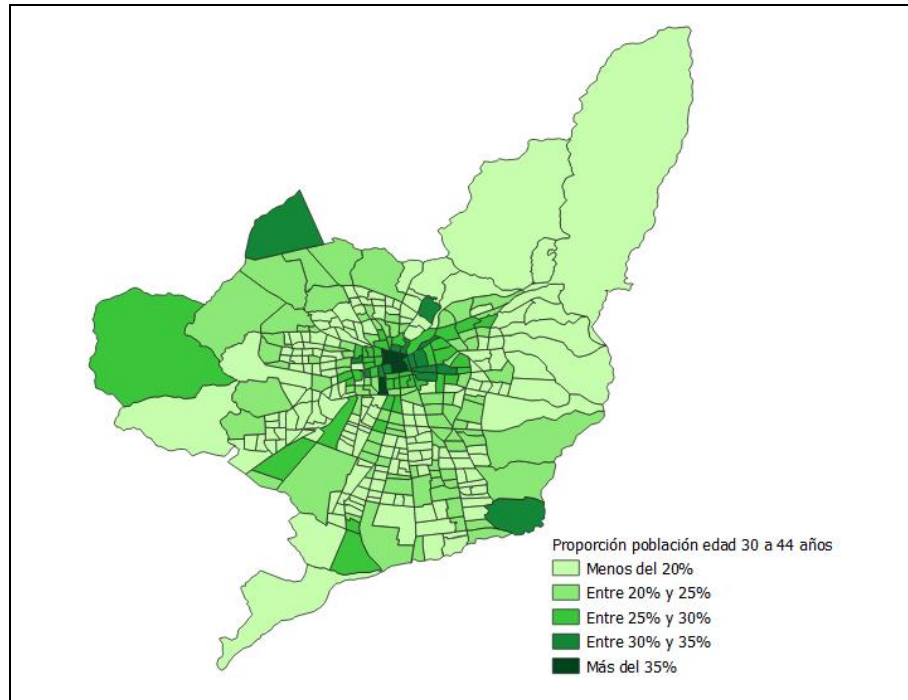
Fuente: Elaboración Propia en INE (2017)

Se espera que los sectores de la ciudad con mayor presencia de población joven tengan una menor recuperación de la movilidad en transporte público. Esto va en línea con las medidas tomadas por la autoridad en el desarrollo de la pandemia por COVID-19, las restricciones impuestas al desplazamiento, el cierre de recintos educativos en el año 2020, la realización de clases en formato no presencial y el retorno gradual a las actividades a fines del año 2021, entre otros.

- Proporción de la población con edad entre 30 y 44 años.

$$\text{Edad}_{30-44} = \frac{\text{Población con edad entre 30 y 44 años en el distrito censal}}{\text{Población total del distrito censal}} \quad (5.8)$$

Figura 5.9: Distribución espacial de la proporción de la población con edad entre 30 y 44 años

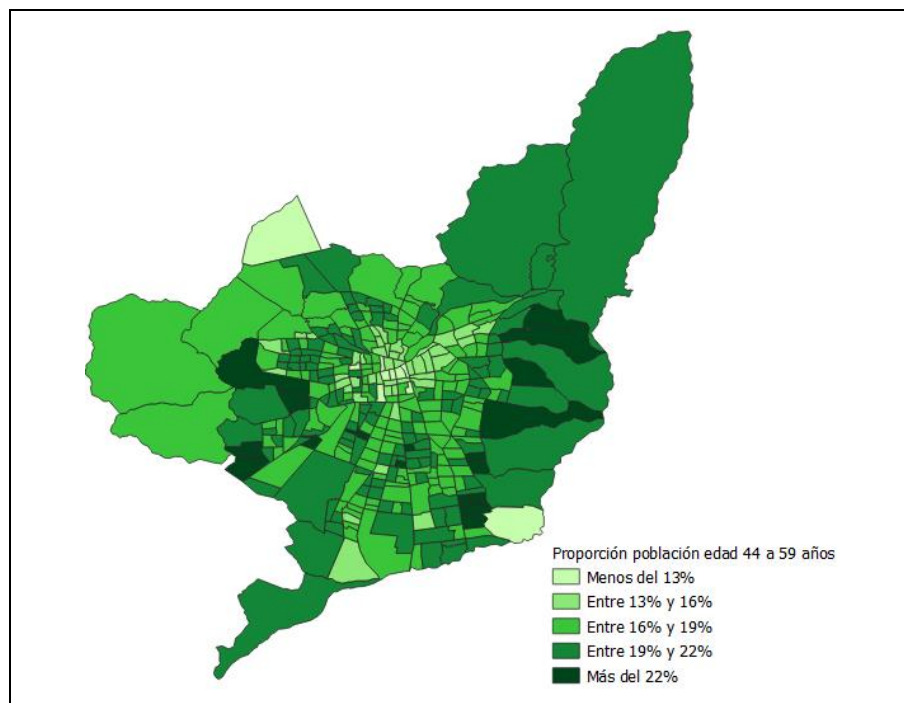


Fuente: Elaboración Propia en INE (2017)

- Proporción de la población con edad entre 45 y 59 años.

$$Edad_{45-59} = \frac{\text{Población con edad entre 45 y 59 años en el distrito censal}}{\text{Población total del distrito censal}} \quad (5.9)$$

Figura 5.10: Distribución de la proporción de la población con edad entre 45 y 59 años



Fuente: Elaboración Propia en INE (2017)

En la tabla siguiente se muestran los estadísticos descriptivos obtenidos para cada una de las variables presentadas anteriormente.

Tabla 5.6: Estadísticos descriptivos de la distribución por grupo etario

VARIABLES explicativas	Unidad	Media	Máx	Min	Desv
Edad ₀₋₁₄	(%)	18%	28%	2%	4%
Edad ₁₅₋₂₉	(%)	24%	44%	16%	3%
Edad ₃₀₋₄₄	(%)	22%	39%	14%	5%
Edad ₄₅₋₅₉	(%)	19%	27%	11%	3%
N° Observaciones		345			

Fuente: INE (2017)

5.1.2.2. Variables explicativas: Cuarentenas

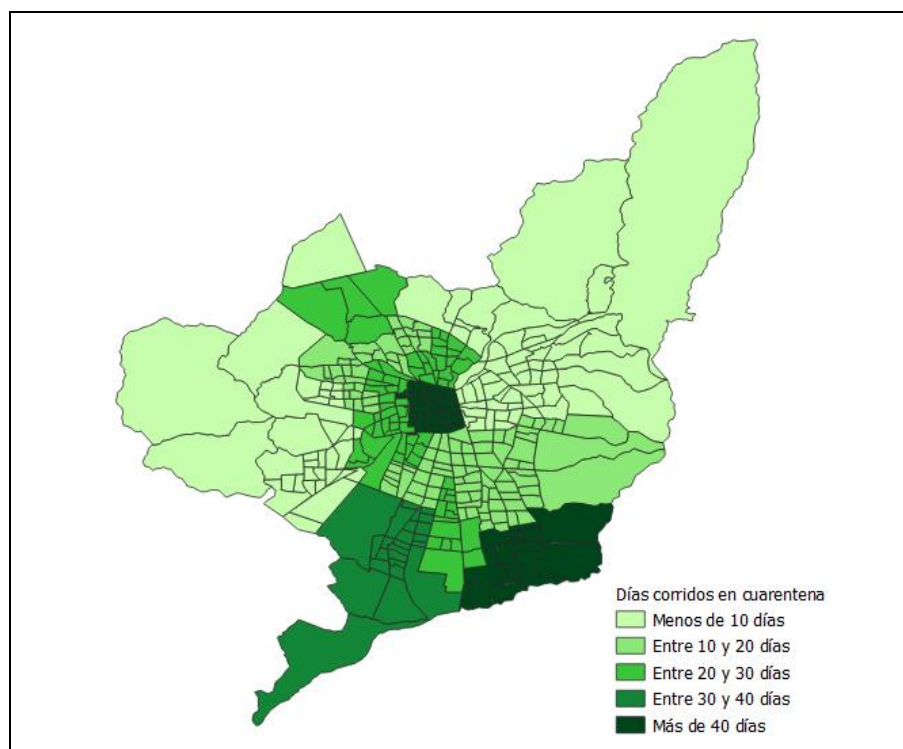
De acuerdo a lo descrito en el capítulo 3.2, es importante recordar que las cuarentenas implementadas por las autoridades impusieron restricciones de desplazamientos y de actividades sobre la población. Para considerar este efecto sobre la recuperación de la movilidad de los usuarios del transporte público en la mañana, y analizar su impacto a través del territorio, se incluyó la siguiente variable explicativa.

- *Días corridos en cuarentena:* Corresponde a la cantidad de días consecutivos que la comuna en la que se localiza el distrito censal estuvo en cuarentena, teniendo en consideración el carácter dinámico de estas, es decir, las restricciones diferían a través del territorio en función de la tasa de contagios, la concentración de infectados, entre otros parámetros.

Dado que esta variable requiere que el área se encuentre en cuarentena durante el periodo en análisis, solo será posible estimarla para los cortes temporales de mayo 2020 y junio 2020, en los inicios de la pandemia por COVID-19.

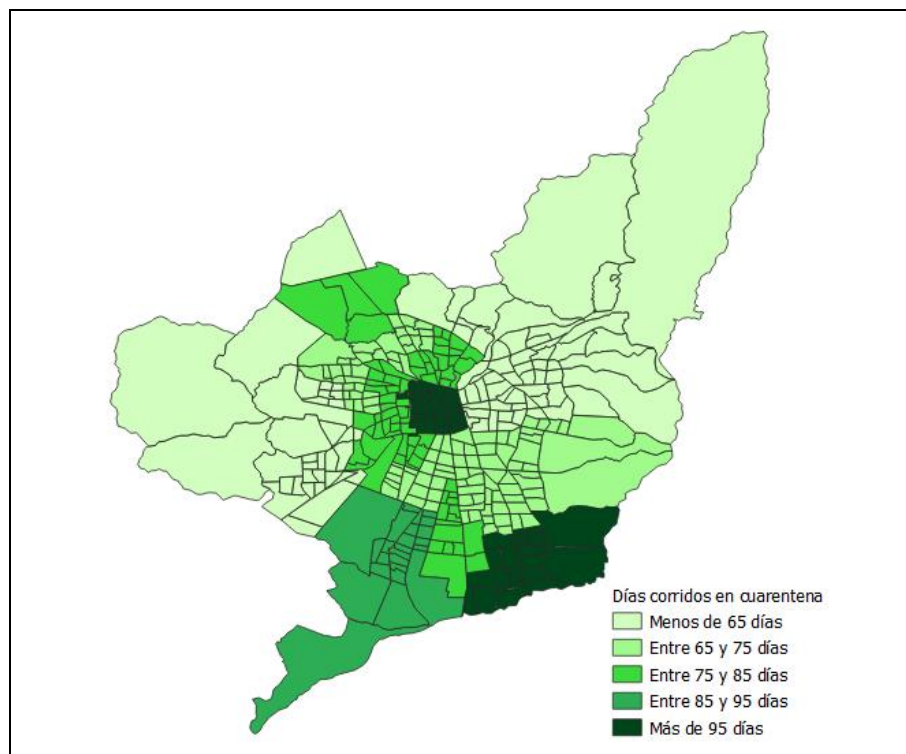
Se contabilizan entonces los días transcurridos desde que el área en cuestión entró en cuarentena, hasta la semana representativa del respectivo corte temporal. La distribución espacial de la variable en cuestión se muestra en las figuras a continuación.

Figura 5.11: Distribución espacial de los días corridos en cuarentena, corte temporal mayo 2020



Fuente: Elaboración Propia en base a ISCI & Entel OCEAN (2021)

Figura 5.12: Distribución espacial de los días corridos en cuarentena, corte temporal julio 2020



Fuente: Elaboración Propia en base a ISCI & Entel OCEAN (2021)

Se espera que mientras más días consecutivos lleve un área en cuarentena, mayor sea la recuperación de la movilidad. Esto debido a que parte de la población puede evidenciar cansancio y desgaste ante las medidas sanitarias y los largos periodos de encierro, lo cual se refleja en el incumplimiento del confinamiento recomendado por las autoridades.

En la tabla a continuación se presentan los estadísticos descriptivos de la variable explicativa antes señalada.

Tabla 5.7: Estadísticos descriptivos de los días corridos en cuarentena

Variables explicativas	Unidad	Media	Máx	Mín	Desv
Días cuar corr _{mayo}	Días	21	56	7	15
Días cuar corr _{julio}	Días	77	112	63	15
N° Observaciones		345			

Fuente: Elaboración Propia en base a ISCI & Entel OCEAN (2021)

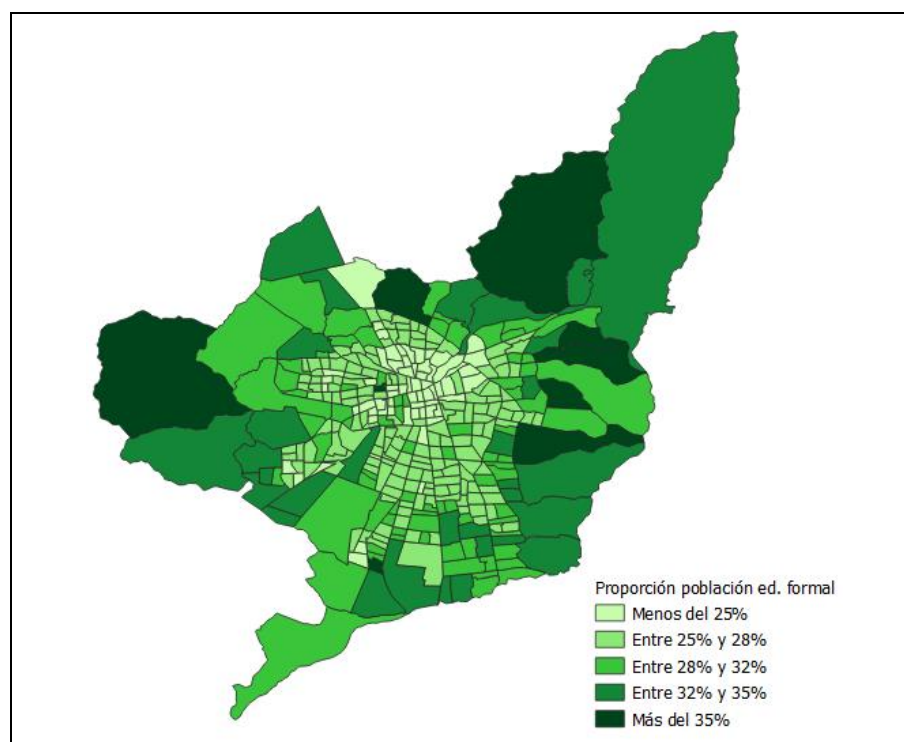
5.1.2.3. Variables explicativas: Educación

Con la finalidad de reflejar el impacto de los estudiantes en el uso diario del transporte público de la ciudad y cómo la suspensión de las clases presenciales en establecimientos educacionales producto de la pandemia por COVID -19 pudo afectar a la recuperación de la movilidad de los usuarios del transporte público en la mañana, se incorporó la siguiente variable explicativa.

- *Proporción de la población en la educación formal:* A partir de la información recopilada en el último CENSO realizado (INE, 2017), se obtuvo para cada distrito censal el número de habitantes que asiste a la educación formal, la cual incluye todos los niveles de escolaridad (educación preescolar, primaria, secundaria y superior). Luego, la proporción de la población que asiste a la educación formal se define según la expresión:

$$\text{Educ Form} = \frac{\text{Población del distrito censal que asiste a la educación formal}}{\text{Población total del distrito censal}} \quad (5.10)$$

Figura 5.13: Distribución espacial de la proporción de la población que asiste a la educación formal



Fuente: Elaboración Propia en INE (2017)

Se espera que las zonas con mayor proporción de asistentes a la educación formal posean una menor recuperación de la movilidad en transporte público. Esto va en línea con las medidas tomadas por la autoridad en el desarrollo de la pandemia por COVID-19, el cierre de recintos educativos en el año 2020, la realización de clases en formato no presencial y el retorno gradual a

las actividades a fines del año 2021, entre otros. En la tabla siguiente se muestran los estadísticos descriptivos obtenidos para la variable explicativa.

Tabla 5.8: Estadísticos descriptivos de la proporción de la población en educación formal

VARIABLES EXPLICATIVAS	UNIDAD	Media	Máx	Min	Desv
Educ Form	(%)	28%	43%	14%	4%
N° Observaciones		345			

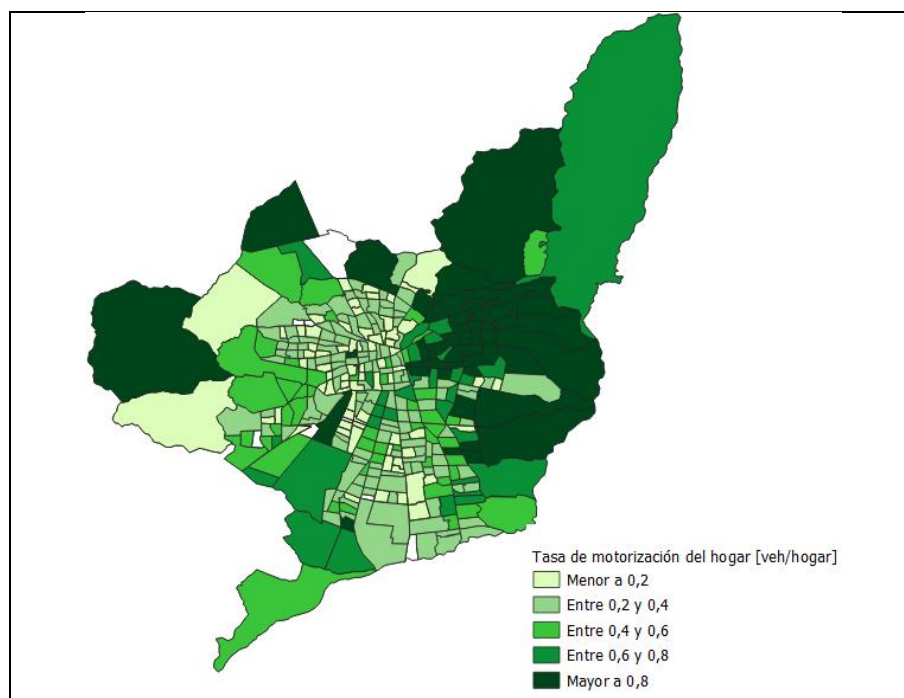
Fuente: INE (2017)

5.1.2.4. Variables explicativas: Accesibilidad al transporte

Para capturar efectos de la accesibilidad al transporte, es decir, la facilidad con que cualquier actividad o uso de suelo puede ser alcanzado desde una localización utilizando un sistema de transporte particular (Dalvi y Martín, 1976), y como esta pudo haber afectado la recuperación de la movilidad de los usuarios del transporte público en la mañana, se consideraron las variables explicativas que se describen a continuación.

- *Tasa de motorización por hogar:* A partir de la información recogida en la EOD (MTT, 2012), se determinó la cantidad de vehículos promedio por hogar, para cada distrito censal, lo cual queda representado en la figura a continuación.

Figura 5.14: Distribución espacial de la tasa de motorización por hogar



Fuente: MTT (2012)

Se espera que aquellos sectores con mejor acceso al automóvil muestren una menor recuperación del transporte público. Esto se debe, por un lado, a que posiblemente disponen de más recursos para escoger otro modo de viaje. Sin embargo, hay que tener en cuenta que las personas mostraron inclinación por utilizar modos de transporte individuales por sobre los masivos, ante el miedo a contagiarse de COVID-19.

En la tabla siguiente se muestran los estadísticos descriptivos obtenidos para la variable explicativa.

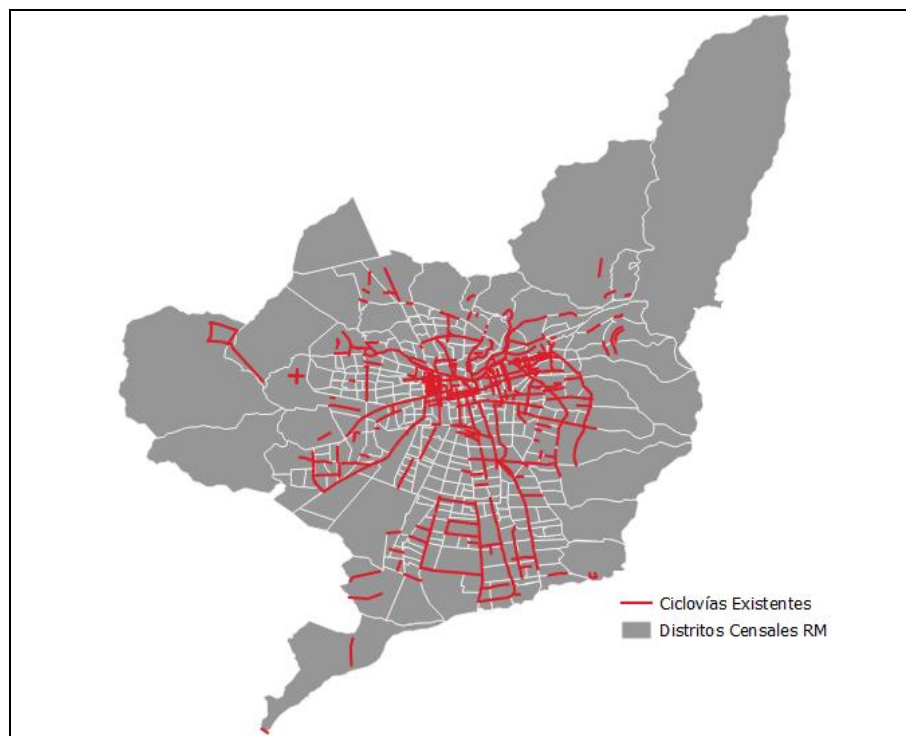
Tabla 5.9: Estadísticos descriptivos de la tasa de motorización por hogar

VARIABLES EXPLICATIVAS	UNIDAD	Media	Máx	Min	Desv
T mot _h	veh/hogar	0,5	2,4	0,0	0,4
N° Observaciones		336			

Fuente: MTT (2012)

- *Número de ciclovías:* Variable independiente que representa la cantidad de ciclovías existentes en cada área geográfica. Para su obtención se utilizó el visor territorial de ciclovías, herramienta elaborada por el Ministerio de Transporte y Telecomunicaciones en conjunto con el Ministerio de Bienes Nacionales en el año 2021, que permite visualizar geográficamente la infraestructura existente, en ejecución y planificada, a nivel comunal y regional.

Figura 5.15: Distribución espacial de las ciclovías existentes



Fuente: Elaboración propia en base a MTT & MBN (2021)

Se espera que las zonas con mayor presencia de ciclovías muestren una menor recuperación del transporte público. La pandemia trajo consigo el crecimiento de los modos no motorizados, reflejado en un mayor número de viajes y más infraestructura. Luego, las personas tienen más alternativas al momento de transportarse. También se debe tener en cuenta que la población mostró preferencia por escoger modos de transporte individuales en vez de los masivos, evitando el contacto social. En la tabla a continuación se presentan los estadísticos descriptivos de la variable explicativa antes descrita.

Tabla 5.10: Estadísticos descriptivos del número de ciclovías existentes

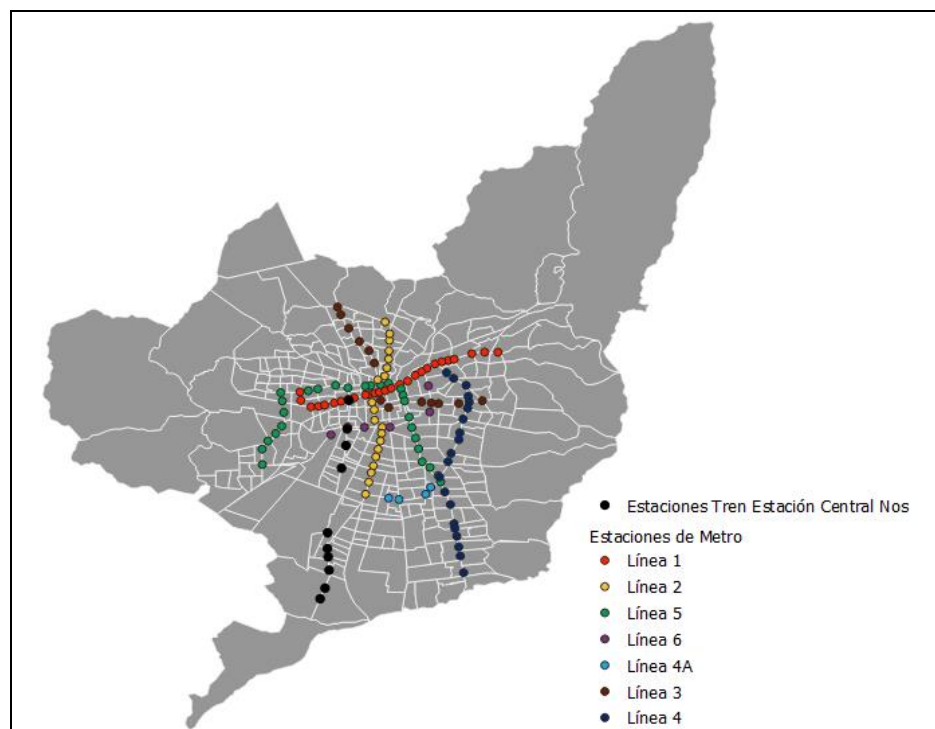
VARIABLES EXPLICATIVAS	UNIDAD	Media	Máx	Min	Desv
N Ciclo	Ciclovías	2	13	0	2
N° Observaciones		345			

Fuente: Elaboración propia en base a MTT & MBN (2021)

- *Estaciones de Metro y Tren:* Con la finalidad de representar la presencia de estaciones de Metro de Santiago y/o del Tren Estación Central-Nos, se consideró la siguiente variable binaria, la cual toma valor uno si en el distrito censal existe alguna estación y cero en caso contrario.

$$\delta_{\text{estación}} = \begin{cases} 1 & \text{si en el distrito censal existe alguna estación de metro o tren} \\ 0 & \text{en caso contrario} \end{cases} \quad (5.11)$$

Figura 5.16: Distribución espacial de las estaciones de metro y tren



Fuente: Elaboración propia

El porcentaje de veces que la variable tipo dummy toma valor uno se detalla en la tabla a continuación. Se puede observar que, de acuerdo a los antecedentes disponibles, poco más de la mitad de las áreas geográficas estudiadas poseen alguna estación de metro o tren.

Tabla 5.11: Descripción variable de tipo dummy asociada a la existencia de estaciones de metro o tren

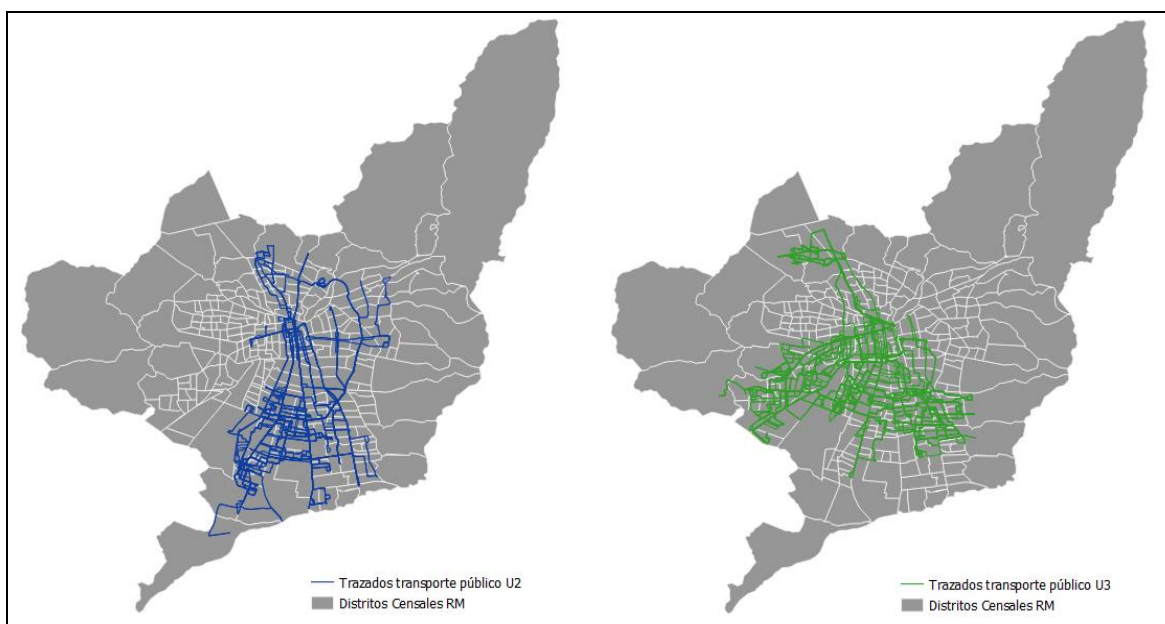
Existencia de estaciones de metro o tren	$\delta_{\text{estación}}$	
	Frecuencia	Porcentaje
0	168	49%
1	177	51%
N° Observaciones	345	

Fuente: Elaboración Propia

Se espera que las zonas con presencia de estaciones de metro o tren muestren una mayor recuperación de la movilidad en transporte público, ya que poseen más alternativas de conexión con el sistema.

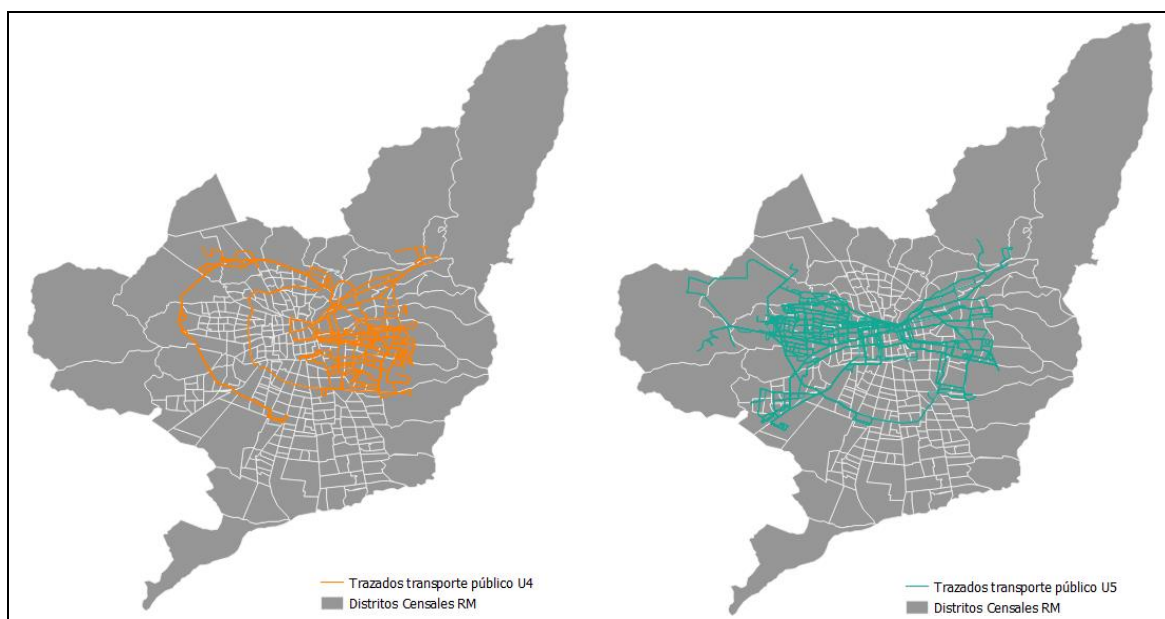
- *Número de servicios de bus:* Variable independiente que representa la cantidad de servicios de transporte público mediante bus, existentes en cada área geográfica. Para su obtención se utilizó el Programa de Operación elaborado por el DTP durante el año 2021. Este entrega las principales características de cada servicio, entre ellas, el detalle del trazado, el que se observa en las siguientes figuras agrupadas por empresa operadora.

Figura 5.17: Distribución espacial de los servicios de transporte público mediante bus, operados por las Unidades de Negocios U2 Subus Chile y U3 Buses Vule



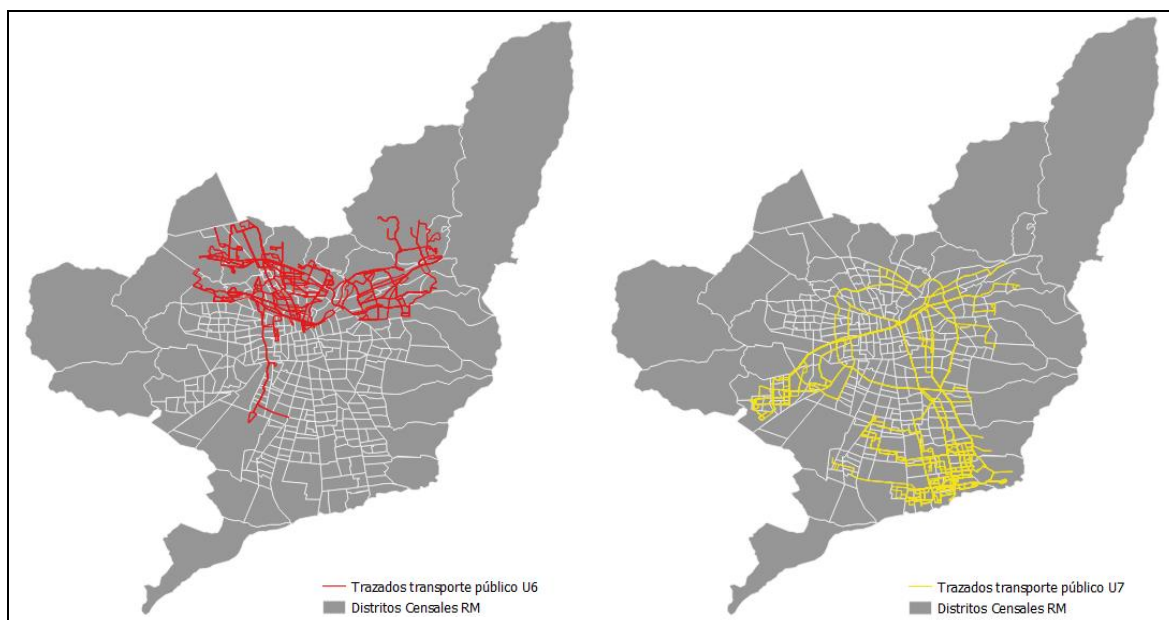
Fuente: Elaboración propia en base a DTP (2021)

Figura 5.18: Distribución espacial de los servicios de transporte público mediante bus, operados por las Unidades de Negocios U4 Voy Santiago SPA y U5 Metbus



Fuente: Elaboración propia en base a DTP (2021)

Figura 5.19: Distribución espacial de los servicios de transporte público mediante bus, operados por las Unidades de Negocios U6 Redbus Urbano y U7 STP



Fuente: Elaboración propia en base a DTP (2021)

Se espera que los sectores con mayor cantidad de servicios de buses, es decir, zonas más densas, muestren una mayor recuperación de la movilidad en transporte público, ya que cuentan con mejor accesibilidad al sistema y entregan más alternativas de conectividad. En la tabla a continuación se presentan los estadísticos descriptivos de la variable explicativa descrita.

Tabla 5.12: Estadísticos descriptivos del número de servicios de bus

Variables explicativas	Unidad	Media	Máx	Min	Desv
N serv	Servicios de bus	47	170	2	25
N° Observaciones		345			

Fuente: Elaboración propia en base DTP (2021)

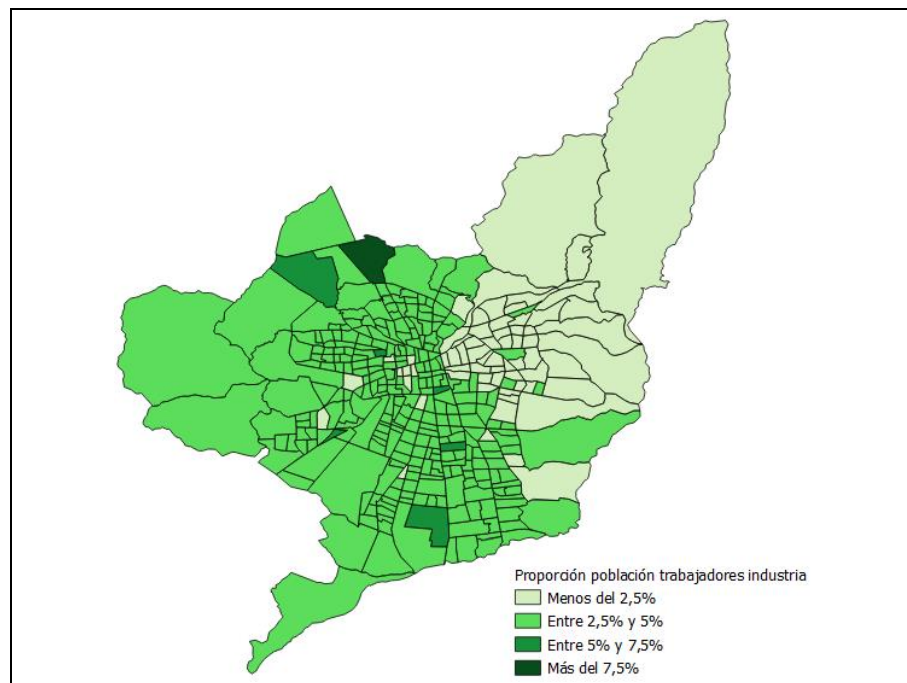
5.1.2.5. Variables explicativas: Trabajo

Con el objetivo de reflejar el impacto de los trabajadores en el uso diario del transporte público y cómo el cierre de servicios y comercios no esenciales debido a la pandemia por COVID-19, junto a la irrupción del teletrabajo en algunos rubros, pudo afectar a la recuperación de la movilidad de los usuarios del transporte público en la mañana, se incorporaron las siguientes variables explicativas.

- *Proporción de la población que trabaja en el rubro de la industria:* A partir de la información recopilada en el último CENSO realizado (INE, 2017), se obtuvo para cada distrito censal el número de habitantes que desempeña labores en el sector industrial. Luego, la proporción de la población que trabaja en el rubro de la industria se define según la expresión:

$$\text{Trab Ind} = \frac{\text{Población del distrito censal que trabaja en el rubro de la industria}}{\text{Población total del distrito censal}} \quad (5.12)$$

Figura 5.20: Distribución espacial de la proporción de la población que trabaja en el rubro industrial

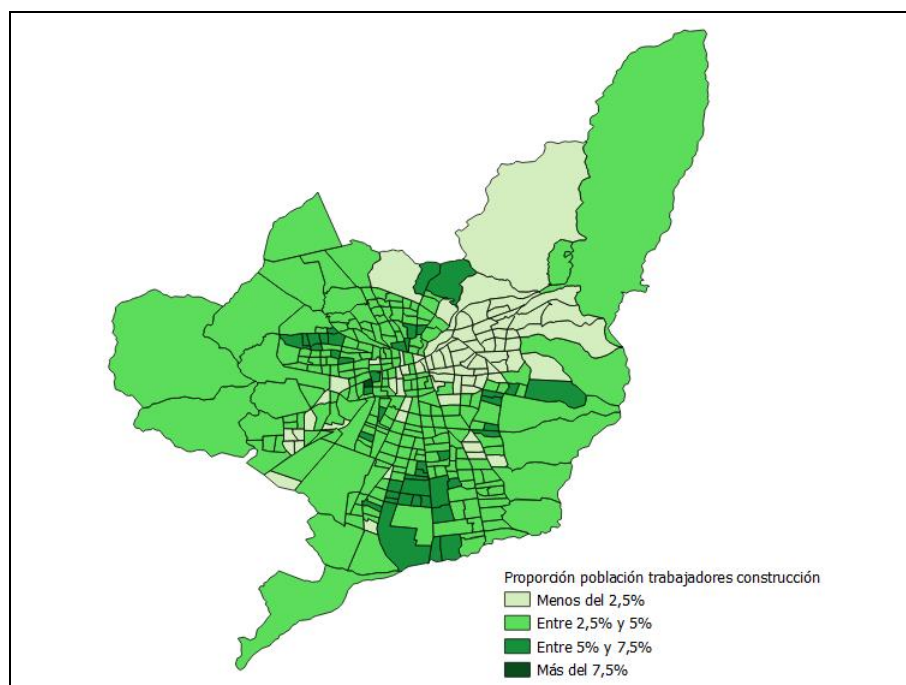


Fuente: Elaboración Propia en INE (2017)

- *Proporción de la población que trabaja en el rubro de la construcción:* A partir de la información recopilada en el último CENSO realizado (INE, 2017), se determinó para cada distrito censal el número de habitantes que desempeña labores en el sector de la construcción. Así, la proporción de la población que trabaja en dicho rubro se calcula de acuerdo a la expresión:

$$\text{Trab Cons} = \frac{\text{Población del distrito censal que trabaja en el rubro de la construcción}}{\text{Población total del distrito censal}} \quad (5.13)$$

Figura 5.21: Distribución espacial de la proporción de la población que trabaja en el rubro de la construcción

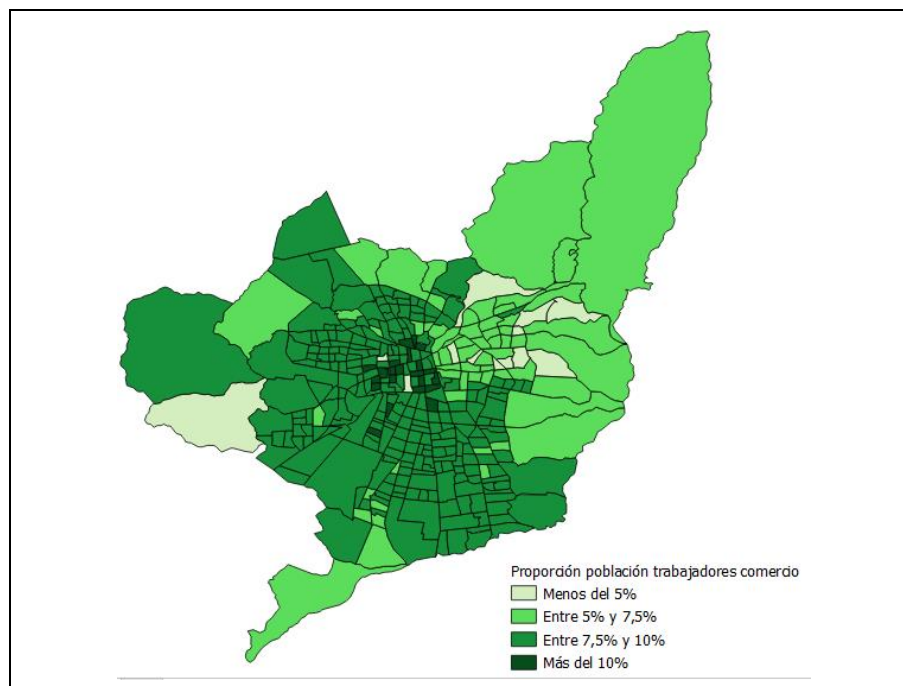


Fuente: Elaboración Propia en INE (2017)

- *Proporción de la población que trabaja en el rubro del comercio:* A partir de la información recopilada en el último CENSO realizado (INE, 2017), se obtuvo para cada distrito censal el número de habitantes que desempeña labores en el sector del comercio. Con ello, la proporción de la población que trabaja en este rubro se determina de la expresión:

$$\text{Trab Com} = \frac{\text{Población del distrito censal que trabaja en el rubro del comercio}}{\text{Población total del distrito censal}} \quad (5.14)$$

Figura 5.22: Distribución espacial de la proporción de la población que trabaja en el rubro del comercio

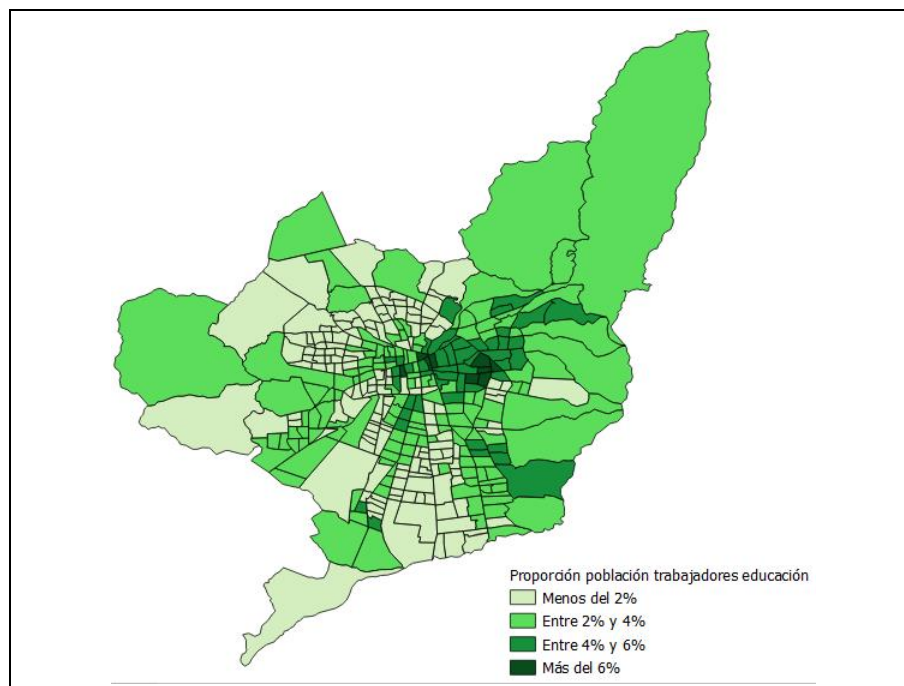


Fuente: Elaboración Propia en INE (2017)

- *Proporción de la población que trabaja en el rubro de la educación:* A partir de la información recopilada en el último CENSO realizado (INE, 2017), se obtuvo para cada distrito censal el número de habitantes que desempeña labores en el sector educacional. Por tanto, la proporción de la población que trabaja en el rubro de la educación se define según la expresión:

$$\text{Trab Ed} = \frac{\text{Población del distrito censal que trabaja en el rubro de la educación}}{\text{Población total del distrito censal}} \quad (5.15)$$

Figura 5.23: Distribución espacial de la proporción de la población que trabaja en el rubro de la educación



Fuente: Elaboración Propia en INE (2017)

Al igual que en las variables anteriores relacionadas con la educación, se espera que las zonas con mayor proporción de trabajadores en este rubro posean una menor recuperación de la movilidad en transporte público, debido al cierre de recintos educativos en el año 2020, la realización de clases en formato no presencial y el retorno gradual a las actividades a fines del año 2021, entre otros. En la tabla siguiente se resumen los estadísticos descriptivos para cada una de las variables antes identificadas.

Tabla 5.13: Estadísticos descriptivos de la proporción de la población que trabaja en los rubros de la industria, construcción, comercio y educación

Variables explicativas	Unidad	Media	Máx	Min	Desv
Trab Ind	(%)	3%	9%	1%	1%
Trab Cons	(%)	4%	9%	1%	1%
Trab Com	(%)	8%	33%	2%	2%
Trab Ed	(%)	3%	8%	1%	1%
N° Observaciones		345			

Fuente: INE (2017)

5.1.3. Hipótesis de modelación

Para concluir el presente capítulo, en la siguiente tabla se expone la influencia esperada de cada variable explicativa propuesta. Notar que existen variables independientes cuya contribución no resulta predecible.

Tabla 5.14: Influencia esperada de las variables explicativas sobre la recuperación de la movilidad de los usuarios del transporte público en la mañana

Categoría	Unidad	Variable explicativa	Efecto esperado
Sociodemográfica	(-)	Nivel de ingreso mensual por hogar bajo	Incrementa
	(-)	Nivel de ingreso mensual por hogar alto	Reduce
	(%)	Proporción de la población mujer	No es claro
	(%)	Proporción de la población con edad entre 0 y 14 años	Reduce
	(%)	Proporción de la población con edad entre 15 y 29 años	Reduce
	(%)	Proporción de la población con edad entre 30 y 44 años	No es claro
	(%)	Proporción de la población con edad entre 45 y 60 años	No es claro
Cuarentenas	(días)	Días corridos en cuarentena	Incrementa
Educación	(%)	Proporción de la población en la educación formal	Reduce
Accesibilidad al transporte	(veh/hogar)	Tasa de motorización por hogar	Reduce
	(ciclovías)	Número de ciclovías	Reduce
	(-)	Estaciones de metro y tren	Incrementa
	(servicios)	Número de servicios de bus	Incrementa
Trabajo	(%)	Proporción de la población que trabaja en el rubro de la industria	No es claro
	(%)	Proporción de la población que trabaja en el rubro de la construcción	No es claro
	(%)	Proporción de la población que trabaja en el rubro del comercio	No es claro
	(%)	Proporción de la población que trabaja en el rubro de la educación	Reduce

Fuente: Elaboración Propia

5.2. Resultado de los modelos de regresión lineal mediante MCO

En la siguiente sección se exponen los resultados obtenidos a partir de la estimación de modelos de regresión lineal, para los cinco cortes temporales representativos de diferentes momentos de la pandemia por COVID -19 (mayo, julio y noviembre 2020, julio y noviembre 2021), contemplando como situación de referencia al corte temporal de marzo 2020.

Se considera por variable dependiente al indicador de recuperación de la movilidad de los usuarios del transporte público en la mañana, denotado como $Rec_{pm,t,i}$, donde t corresponde al corte temporal e i al distrito censal analizado. El indicador fue descrito en el acápite 5.1.1, cuya expresión se recuerda a continuación.

$$Rec_{pm,t,i} = \frac{\text{Nº Usuarios con su primer viaje del día en la mañana, desde el distrito } i, \text{ en el corte temporal } t}{\text{Nº Usuarios con su primer viaje del día en la mañana, desde el distrito } i, \text{ en marzo 2020}} \quad (5.16)$$

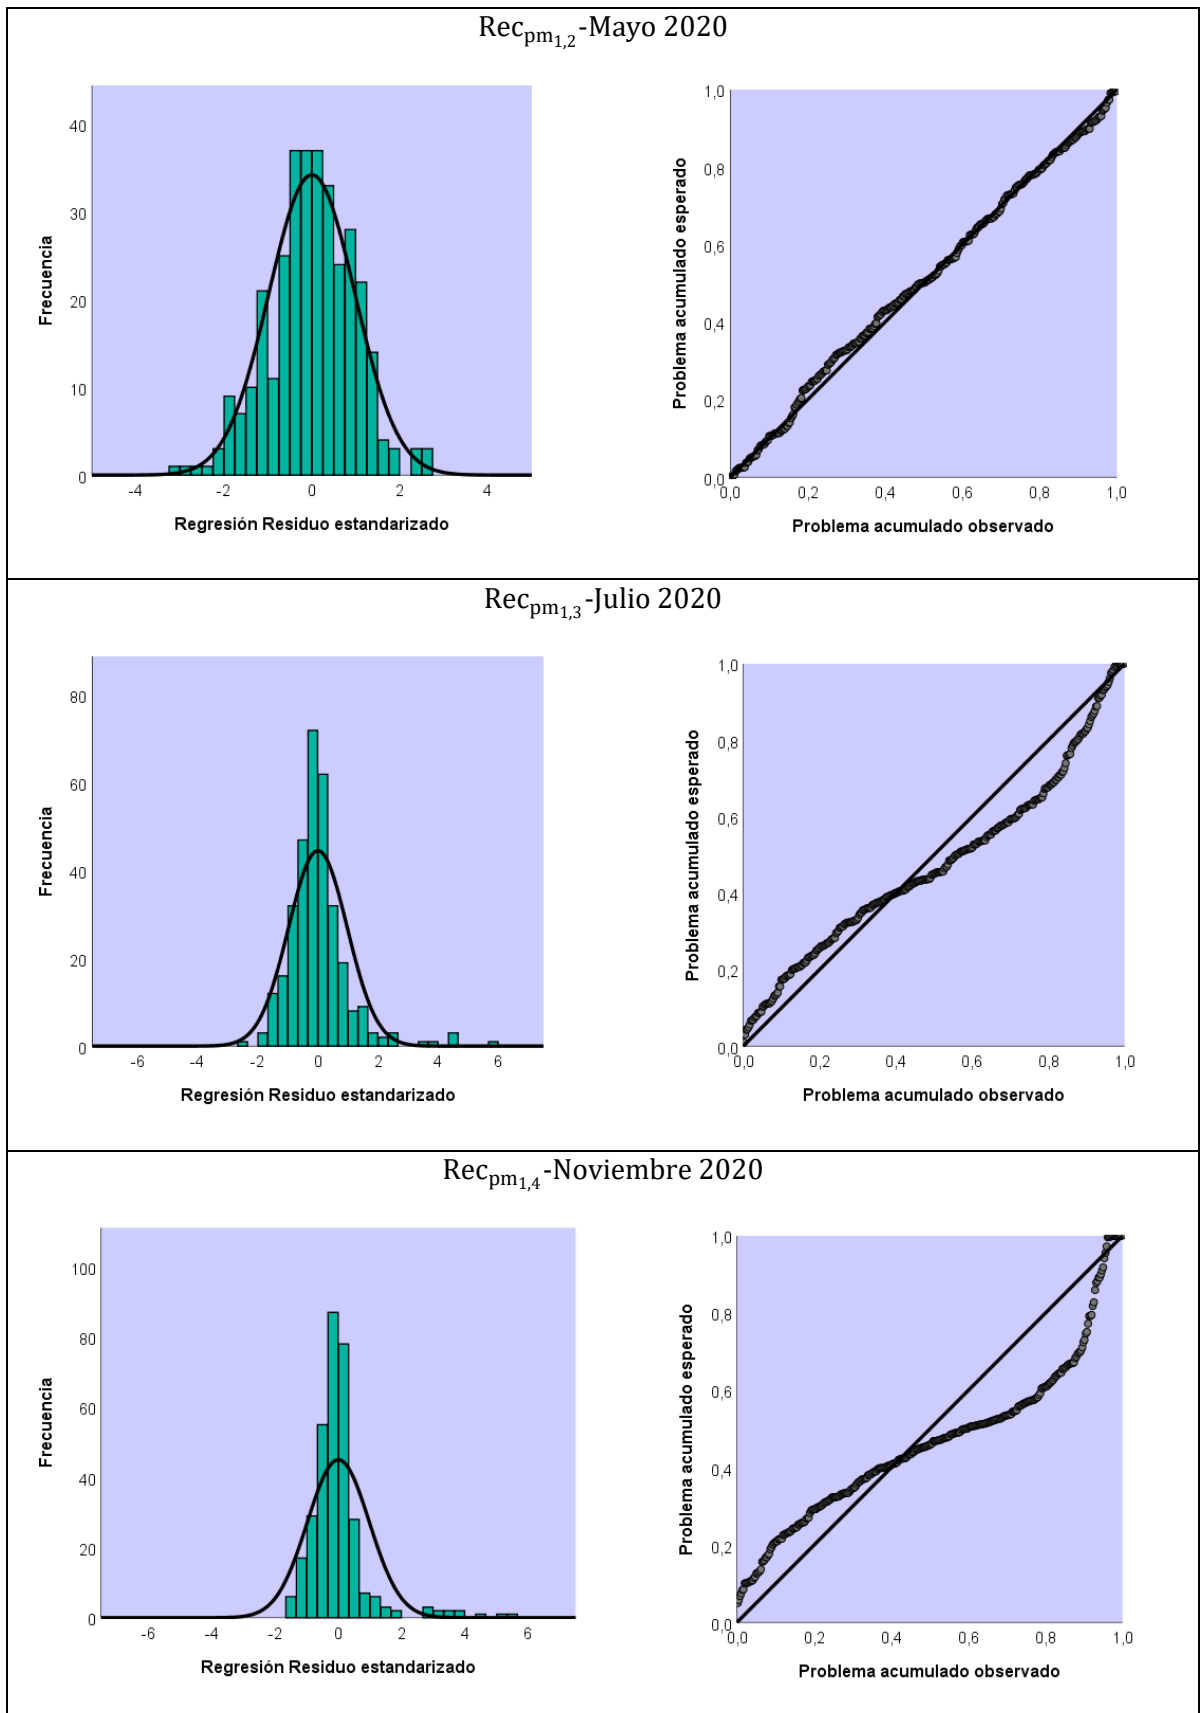
La verificación de los supuestos de regresión lineal múltiple permite garantizar la validez de los modelos planteados. Luego, las condiciones que deben ser cumplidas son: errores normalmente distribuidos, homocedásticos o de igual de varianza y no autocorrelacionados, no colinealidad entre variables independientes y por último, linealidad (Tabachnick y Fidell, 2012).

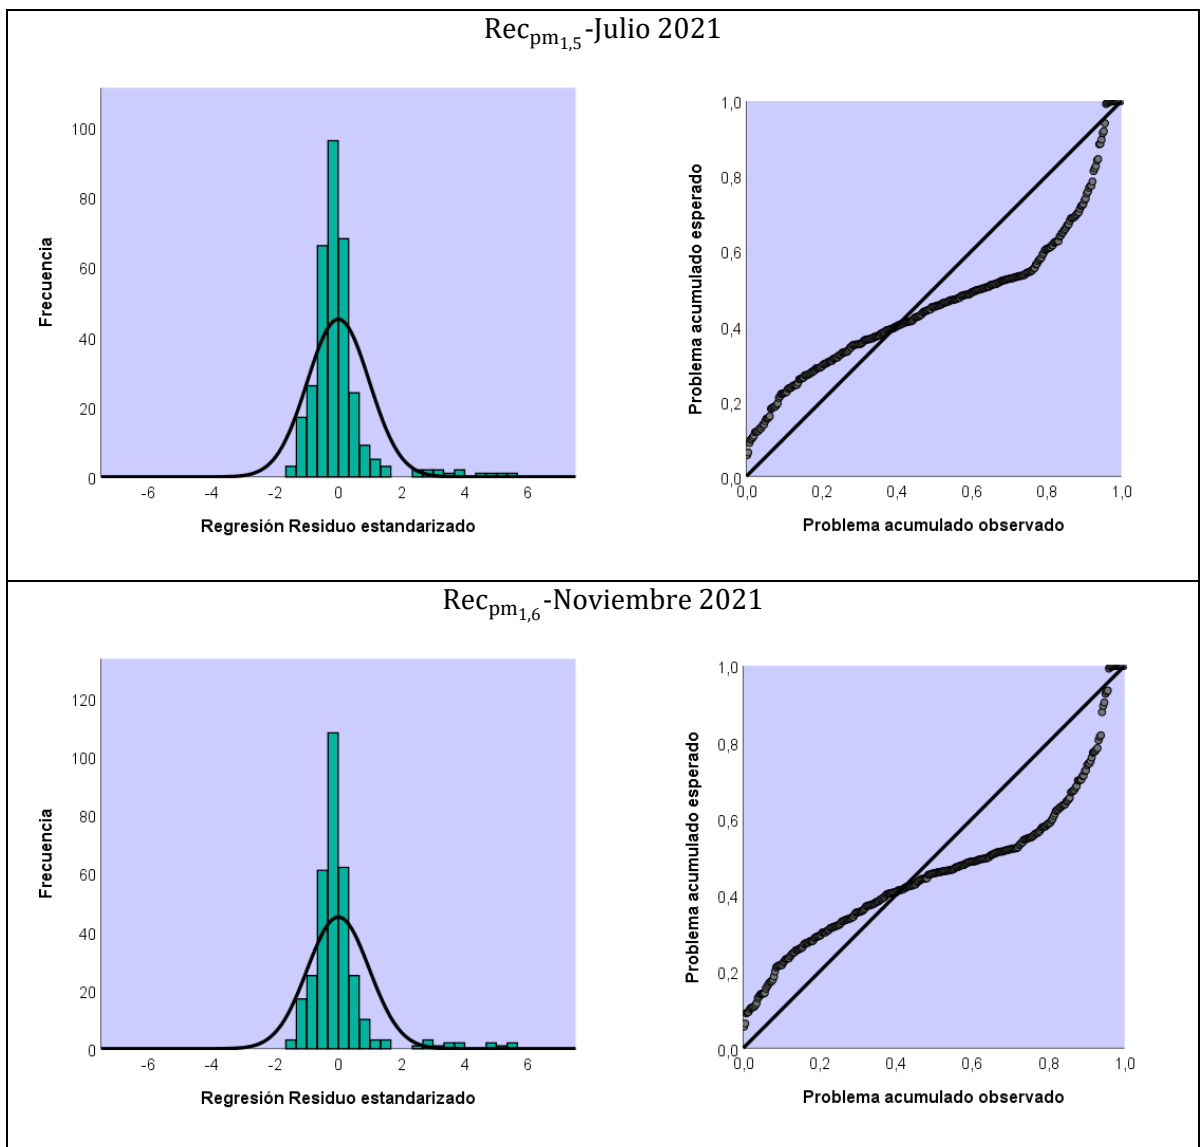
Con respecto al supuesto de normalidad, en las figuras que siguen se presentan histogramas de residuos junto a la respectiva curva asociada $N(0,1)$ y gráficos de probabilidad normal de tipo P-P (proporciones). Se observa que para el primer corte temporal analizado (mayo 2020) la distribución de los errores tiende en mayor medida a una normal, mientras que con el transcurso del tiempo se notan mayores distorsiones.

Los resultados anteriores fueron verificados mediante la aplicación del test de Shapiro-Wilk sobre los residuos de cada modelo, cuya hipótesis nula plantea que la distribución es normal. Por tanto, se rechaza dicha hipótesis si el p-valor de la prueba es menor a 0,05. Cabe destacar que al realizar la prueba se obtuvieron las mismas conclusiones, donde el p-valor supera el umbral de 0,05 solo para el corte temporal de mayo 2020, mientras que en los cortes temporales restantes se rechaza la hipótesis nula, es decir, la distribución de los errores no es normal.

Si bien la verificación de este supuesto justifica el uso de pruebas estadísticas que involucren distribuciones t y F , la no normalidad solo compromete la eficiencia, pero no la consistencia ni el insesgamiento de los estimadores. Adicionalmente, afecta a los errores estándar al realizar inferencia, sin embargo, en presencia de grandes muestras (por sobre 100 observaciones) es posible reclamar leyes de grandes números para utilizar test asintóticamente normales. Por tanto, a pesar de que se detectan desviaciones de la normalidad en la mayoría de los cortes temporales, dado que las muestras usadas son grandes, los test estadísticos t y F no se ven afectados.

Figura 5.24: Histogramas de residuos y gráficos de probabilidad normal de tipo P-P, por corte temporal

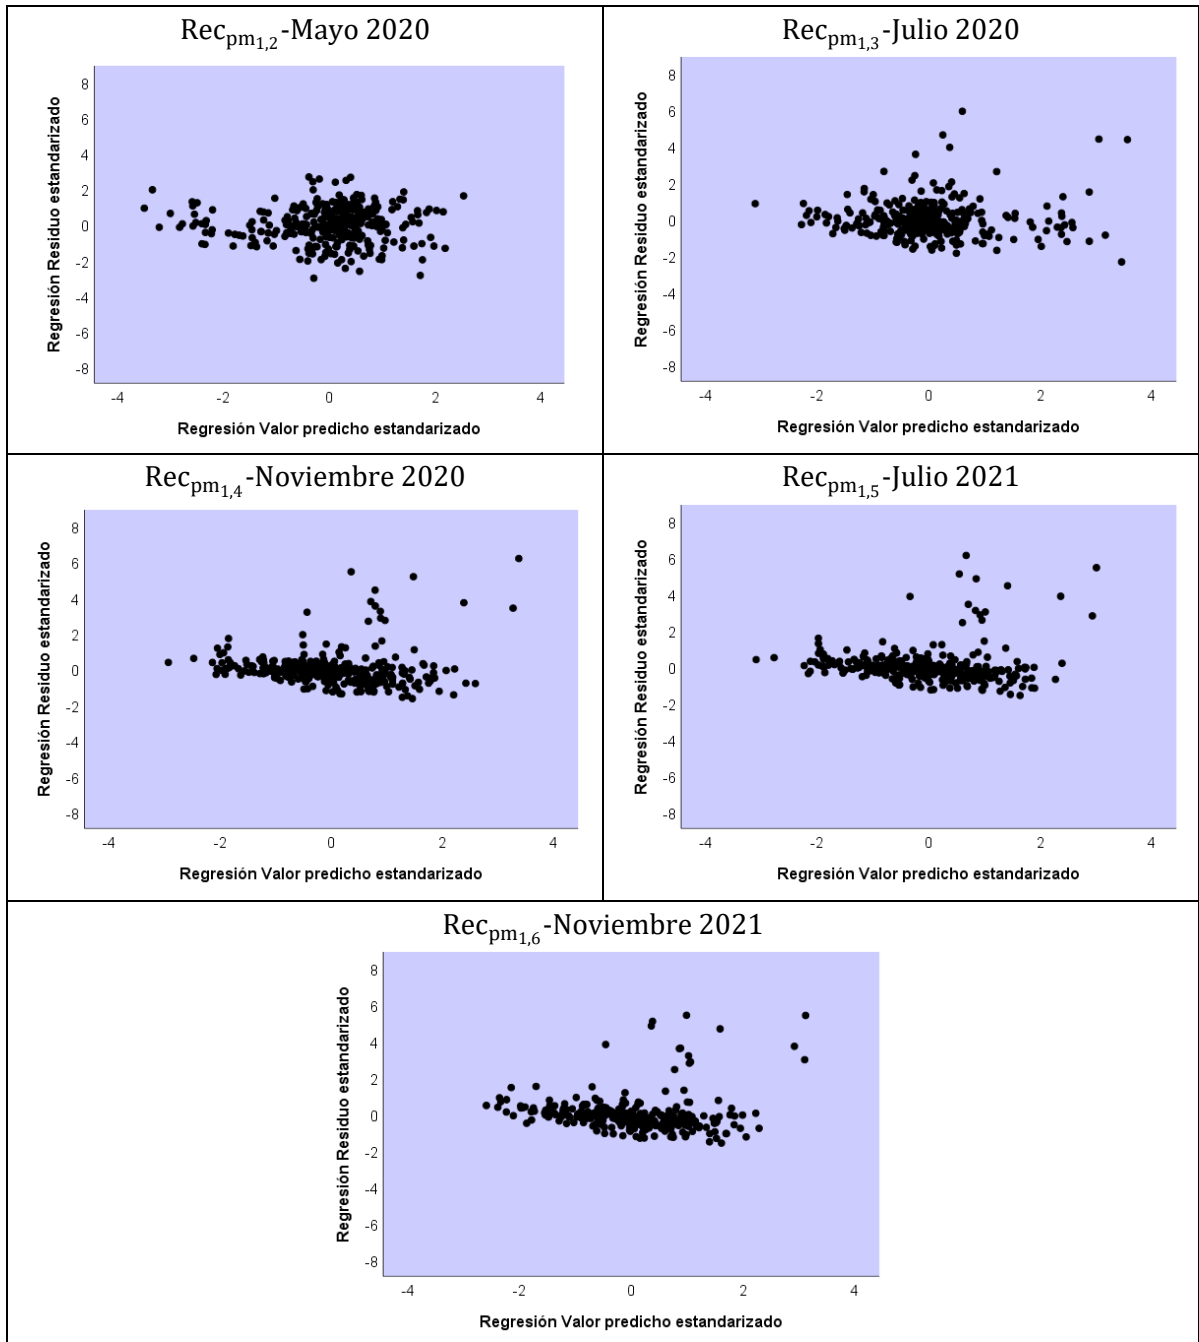




Fuente: Elaboración Propia

Para estudiar la homocedasticidad de los errores, se analizaron, en primer lugar, los gráficos de dispersión que se muestran en las figuras a continuación. El cumplimiento de este supuesto requiere que la banda que encierra los residuos sea aproximadamente uniforme en todo el rango de valores predichos. Si se detecta heteroscedasticidad, entonces el estimador MCO sigue siendo lineal e insesgado, pero deja de ser eficiente ya que no es el estimador de mínima varianza y con ello, las inferencias realizadas a partir de los contrastes de significación pierden validez (Tabachnick y Fidell, 2012).

Figura 5.25: Diagramas de dispersión, por corte temporal



Fuente: Elaboración Propia

Basándose en la representación gráfica de los residuos, se observa en cada corte temporal un aparente comportamiento no homogéneo. En los primeros (mayo y junio 2020) la dispersión tiende a variar a lo largo de las observaciones de la muestra. A su vez, para los cortes temporales restantes (noviembre 2020, julio y noviembre 2021), si bien se evidencia una banda prácticamente uniforme, esta presenta una muy leve pendiente que sugeriría una relación lineal entre los residuos y la variable.

Otro método para verificar la homocedasticidad corresponde a la realización de contrastes, donde uno de los más generales es el de White, el cual será presentado posteriormente. Este plantea como hipótesis nula la existencia de homocedasticidad, por tanto, se rechazará dicha hipótesis si el p-valor del contraste es menor a 0,05. En la tabla 5.15 se puede notar que el p-valor supera el umbral de 0,05 para prácticamente todos los cortes temporales. Solo en el corte temporal de noviembre 2020 se rechaza la hipótesis nula, es decir, se detecta existencia de heterocedasticidad.

Cuando las varianzas de los residuos son desiguales se recomienda realizar una regresión lineal con errores estándares robustos para estimar los parámetros, lo cual permite el uso de los test t y F sin que se vean afectados. La diferencia entre la regresión lineal típica mediante mínimos cuadrados ordinarios (MCO) y la robusta a través de la técnica de mínimos cuadrados generalizados (MCG) se encuentra en la minimización realizada. Por un lado, MCO minimiza la suma de cuadrados de los residuos, mientras que MCG minimiza una suma ponderada de residuos al cuadrado (Tabachnick y Fidell, 2012). Cabe notar que, al robustecer los errores estándar del modelo, se podrían generar modificaciones en el ajuste del p-valor, no obstante, los parámetros estimados no debiesen cambiar.

Respecto a la autocorrelación de los errores, se determinó en primer lugar el contraste de Durbin-Watson. Si el estadístico toma valores entre 1,5 y 2,5 entonces se sugiere que los errores no están correlacionados (Murillo y González, 2000). En la tabla 5.15 se observa que para cada corte temporal se cumple dicho supuesto.

Sin embargo, dada la naturaleza de los datos utilizados, donde cada observación representa un área geográfica, es necesario verificar también la existencia de dependencia o autocorrelación espacial. Esta surge en aquellos casos donde el valor de una o varias variables en una ubicación se relaciona a los valores de dichas variables en ubicaciones cercanas (Borrego, 2018).

Para revisar la presencia de autocorrelación espacial en los modelos de regresión, se usará el test I de Moran, el cual se aplica sobre los residuos de regresión. Cabe recordar que la obtención de la I de Moran depende de la medida de contigüidad que entrega relaciones de vecindad entre las áreas estudiadas, tal como se describió en el Capítulo 2. Por ende, se estimó a través del software Stata la matriz de pesos espaciales normalizada W , donde cada elemento W_{ij} que la compone corresponde a la relación entre dos áreas vecinas i y j .

El esquema de ponderación utilizado para obtener cada W_{ij} se basa en la función de distancia inversa, de forma tal que los pesos están inversamente relacionados con la distancia existente entre el área i y el área j . Luego, los elementos diagonales de la matriz son cero, mientras que en los elementos no diagonales W_{ij} ($i \neq j$) se calcula el inverso de la distancia, normalizada espectralmente, entre i y j , a partir de la localización geográfica sus centroides.

Finalmente, el test I de Moran plantea como hipótesis nula la ausencia de autocorrelación espacial. Luego, se rechazará dicha hipótesis si el p-valor del contraste es menor a 0,05. En la tabla 5.15 se puede notar que para los cortes temporales de mayo y julio 2020 se obtiene un valor de la prueba que permite rechazar la hipótesis nula y considerar la presencia de autocorrelación espacial. Por ende, en la próxima sección se estimarán modelos de regresión espacial para abordar estos casos y se entregará una comparación de los coeficientes obtenidos entre ambas técnicas consideradas.

Con respecto a la estimación de la significancia individual de las variables, esta se determinará mediante el p-valor de la prueba. Si el p-valor es menor a 0,05 se concluirá que el parámetro estimado para la variable explicativa es significativamente distinto de cero, con un nivel de confianza del 95%. A su vez, si el p-valor es menor a 0,1, el parámetro resultará estadísticamente significativo, con un nivel de confianza del 90%.

Por lo tanto, en la tabla siguiente se muestran los modelos estimados por corte temporal y los parámetros obtenidos para cada variable independiente incluida, mediante la técnica de MCO. Se presenta entre paréntesis el error estándar mientras que, para solucionar la heteroscedasticidad detectada en el corte temporal de Noviembre 2020, se realiza una regresión lineal con errores estándares robustos. Se identifican en negrilla aquellas variables que resultaron estadísticamente significativas en la modelación, indicando con la simbología */+ el rango en el que se encuentra el p-valor.

Con respecto a la bondad de ajuste de los modelos, se incorporan los indicadores R^2 , R^2 Ajustado, AIC (criterio de información de Akaike) y el estadístico Log-Likelihood (logaritmo de la razón de verosimilitud, denotado como LL). Es posible notar que con el paso del tiempo el grado de ajuste de los modelos va decayendo.

Las variables tipo dummy asociadas al nivel de ingreso por hogar resultaron ser estadísticamente significativas. Por un lado, el nivel de ingreso bajo es una de las variables explicativas más relevantes en la modelación, ya que es significativa al 95% en cada corte temporal estudiado, es decir, muestra efectos en el corto, mediano y largo plazo. De acuerdo con el signo de los coeficientes estimados, se deduce que en zonas con menor ingreso es probable evidenciar una mayor recuperación de la movilidad de los usuarios del transporte público en la mañana que en sectores con nivel de ingreso medio, lo cual se encuentra en línea con lo identificado en la literatura y con la hipótesis planteada en el acápite anterior. Efectivamente, esto se debe a que los usuarios de transporte público con menores ingresos se caracterizan por estar cautivos al sistema, no disponer de los recursos que les permitan escoger otros modos de transporte y trabajar en rubros donde se requiere una mayor presencialidad.

Tabla 5.15: Estimación de modelos de regresión lineal múltiple con indicador $Rec_{pm,t}$, por corte temporal

Variables	$Rec_{pm,2}$ Mayo 2020	$Rec_{pm,3}$ Julio 2020	$Rec_{pm,4}$ Nov 2020	$Rec_{pm,5}$ Julio 2021	$Rec_{pm,6}$ Nov 2021
Nivel de ingreso por hogar bajo	0,027** (0,010)	0,110*** (0,025)	0,287* (0,143)	0,230* (0,111)	0,294* (0,135)
Nivel de ingreso por hogar alto	-0,023+ (0,013)	-0,031 (0,033)	-0,132 (0,092)	-0,110 (0,149)	-0,109 (0,182)
Proporción de la población mujer	0,036 (0,135)	0,355 (0,338)	-0,217 (0,858)	-0,411 (1,537)	-0,744 (1,875)
Proporción de la población con edad entre 15 y 29 años	-0,085 (0,112)	-0,109 (0,284)	-2,100** (0,765)	-2,236+ (1,215)	-3,008* (1,482)
Proporción de la población con edad entre 30 y 44 años	0,304* (0,126)	0,560+ (0,317)	0,312 (1,012)	0,210 (1,437)	0,167 (1,753)
Proporción de la población con edad entre 45 y 59 años	0,395* (0,185)	0,648 (0,466)	-0,653 (1,382)	-1,045 (2,122)	-1,470 (2,589)
Días corridos en cuarentena	0,000 (0,000)	0,000 (0,001)	-	-	-
Proporción de la población en educación formal	-0,096 (0,096)	-0,202 (0,245)	0,970 (0,813)	1,028 (1,104)	1,639 (1,347)
Tasa de motorización por hogar	-0,018 (0,014)	-0,014 (0,035)	-0,118 (0,100)	-0,165 (0,160)	-0,167 (0,195)
Número de ciclovías existentes	-0,001 (0,001)	-0,009* (0,003)	-0,037** (0,012)	-0,042** (0,016)	-0,053** (0,019)
Presencia de estaciones de Metro y Tren	-0,001 (0,006)	0,015 (0,014)	0,171** (0,060)	0,157* (0,065)	0,220** (0,080)
Número de servicios de bus	0,000 (0,000)	0,001* (0,000)	0,002* (0,001)	0,002+ (0,001)	0,003+ (0,002)
Proporción de la población que trabaja en el rubro de la industria	0,841* (0,340)	-0,261 (0,881)	-5,257+ (2,729)	-6,324 (3,998)	-6,935 (4,877)
Proporción de la población que trabaja en el rubro de la construcción	-0,082 (0,283)	-0,568 (0,716)	-0,988 (2,678)	0,610 (3,239)	-0,865 (3,951)
Proporción de la población que trabaja en el rubro del comercio	0,043 (0,163)	-0,359 (0,411)	-1,394 (1,030)	-2,121 (1,825)	-2,272 (2,227)
Proporción de la población que trabaja en el rubro de la educación	-0,553 (0,356)	-1,761+ (0,910)	-5,812+ (3,362)	-5,301 (4,082)	-5,993 (4,979)
Constante del modelo	0,055	-0,056	1,431	1,813	2,316
Error cuadrático medio	0,045	0,111	0,420	0,509	0,621
R-cuadrado	0,269	0,146	0,140	0,107	0,102
R-cuadrado Ajustado	0,232	0,102	0,099	0,064	0,059
AIC	-1118	-492	381	508	639
LL	576	263	-174	-238	-304
P-valor (White)	0,066	0,117	0,040	0,599	0,537
Durbin Watson	1,543	1,808	1,852	1,963	1,948
P-valor (I de Morán)	0,000	0,027	0,581	0,299	0,310
N observaciones	335	327	331	331	331

+: p-valor<0,10 , *: p-valor<0,05, **: p-valor<0,01, ***: p-valor<0,001

La columna " $Rec_{pm,4}$ Nov 2020" muestra errores estándar robustos entre paréntesis

Fuente: Elaboración Propia

Por otro lado, el nivel de ingreso alto obtuvo significancia estadística al 90% de confianza en el primer corte temporal, en los inicios de la pandemia por COVID-19, y en el corte de noviembre 2020 al 85%. Al analizar el signo del parámetro se obtiene que en las áreas de la ciudad con mayor ingreso la recuperación de la movilidad de los usuarios del transporte público en la mañana fue menor que en zonas con nivel de ingreso medio, siguiendo la tendencia entregada en la literatura. Este efecto en el corto-mediano plazo sugiere que la variable nivel de ingreso alto no es estadísticamente distinta, en el transcurso de la crisis sanitaria, al nivel de ingreso medio, respecto a su implicancia sobre la recuperación de la movilidad.

Sobre las variables proporción de la población mujer y proporción de la población en educación formal, estas no alcanzan la significancia estadística en ninguno de los cortes temporales analizados. Por su parte, las variables explicativas asociadas a grupos etarios muestran diferentes efectos sobre la variable dependiente. En primer lugar, la proporción de la población joven, con edad entre 15 y 29 años, alcanza la significancia estadística en tres cortes temporales, mostrando un efecto en el mediano plazo del desarrollo de la pandemia por COVID-19. Los parámetros estimados señalan que en los sectores con mayor presencia de población joven la recuperación de la movilidad de los usuarios del transporte público en la mañana se ve reducida. Esto concuerda con las restricciones impuestas al desplazamiento, el cierre de recintos educativos y la realización de clases en formato no presencial.

A su vez, tanto la proporción de la población con edad entre 30 y 44 años, como la proporción de la población con edad entre 45 y 59 años son estadísticamente significativas al 95% en los inicios de la emergencia sanitaria. De acuerdo con los signos de los parámetros obtenidos, en áreas con mayor presencia de población adulta la recuperación de la movilidad de los usuarios de transporte público en la mañana se incrementó, mostrando consistencia con lo entregado por el estado del arte.

Este efecto en el corto plazo puede relacionarse con el hecho de que en los primeros meses de pandemia se restringieron considerablemente los desplazamientos. No obstante, parte de los viajes con propósito al trabajo se siguieron realizando, sobre todo si estos eran considerados esenciales y la alternativa de trabajar desde el hogar aún no se formalizaba. Cabe destacar que la mayor actividad laboral se concentra en los estratos de edad intermedia, es decir, entre los 25 y 60 años, donde la edad promedio de los ocupados en Chile es de 43,8 años (INE, 2017).

Con respecto a la variable de días corridos en cuarentena, no resultó ser significativa en los cortes temporales que se incorporó. Esto puede deberse al nivel de agregación que presenta dicha variable, ya que las cuarentenas se implementaron a nivel comunal. Luego, al interior de una comuna no existieron diferencias entre distritos censales, por ende, posee menor variabilidad.

La variable tasa de motorización por hogar no obtiene significancia estadística en ninguno de los cortes temporales estudiados. Si bien se esperaba que tuviese un impacto sobre la recuperación de la movilidad de los usuarios de transporte público en la mañana, se debe notar que la data utilizada para construir la variable es antigua (año 2012). En concreto, para el nivel de desagregación requerido no fue posible obtener información que representara la situación existente en Santiago, donde el parque de vehículos se ha incrementado considerablemente en los últimos años.

El número de ciclovías existentes alcanza significancia estadística, con un nivel de confianza del 95%, en prácticamente todos los cortes temporales, mostrando efectos en el corto, mediano y largo plazo. El signo de los parámetros estimados concuerda con lo esperado, donde las zonas con mayor presencia de ciclovías desfavorecen la recuperación de la movilidad de los usuarios de transporte público en la mañana. Este resultado va en línea con que parte de la población ha optado por los modos no motorizados desde el inicio de la crisis sanitaria, prefiriendo alternativas de transporte individuales que reduzcan el contacto social, mientras que la autoridad ha respondido construyendo más infraestructura vial especializada para ciclos.

La variable tipo dummy asociada a la existencia de estaciones de metro y tren es estadísticamente significativa al 95% en tres cortes temporales, con efecto en el mediano y largo plazo. De acuerdo con el impacto estimado se tiene que las áreas con presencia de estaciones de metro y tren favorecen la recuperación del transporte público, ya que se mejora la conectividad de los usuarios con el sistema. Ciertamente, el metro y el tren se caracterizan porque sus puntos de acceso y salida determinan sectores acotados con un alto valor de accesibilidad, en los que se generan y capturan nuevas demandas, aumentan los flujos peatonales, se crean puntos de trabajo, comercio y servicios, se potencia el desarrollo urbano, entre otros (Mella, 2013). No obstante, se debe tener en cuenta que en la ciudad de Santiago la evasión al pago de la tarifa en metro y tren es menor que en buses, bajo el supuesto de que esta tendencia no cambió durante la pandemia. Por ende, aquellas áreas que solo disponen de servicios de buses podrían registrar una menor recuperación de la movilidad en transporte público que la efectiva, producto de la evasión a la tarifa.

Respecto a la variable número de servicios de bus, esta obtuvo significancia estadística con un nivel de confianza mayor al 90%, en cuatro de los cortes temporales analizados, impactando en el corto, mediano y largo plazo. Los signos de los parámetros señalan que, en las zonas más densas, es decir, con una mayor cobertura de servicios de bus, estos contribuyen a aumentar la recuperación de la movilidad de los usuarios del transporte público en la mañana. Esto concuerda con el efecto esperado, dado que corresponden a áreas con mejor accesibilidad y con más alternativas de conectividad a disposición de los usuarios, lo cual fortalece al sistema.

Las variables independientes asociadas al trabajo presentan diversos efectos sobre la variable explicada. Por un lado, la proporción de la población que trabaja en el rubro de la industria es significativa en el primer corte temporal al 95%, así como también en el mediano plazo del desarrollo de la pandemia por COVID-19 (nivel de confianza superior al 85%). Sin embargo, su impacto sobre la recuperación del transporte público varía con el paso del tiempo.

En el comienzo de la crisis sanitaria se observa que en sectores con mayor proporción de habitantes que trabajan en industrias, la recuperación de la movilidad se incrementó. Este efecto puede explicarse por el hecho de que el rubro industrial fue uno de los considerados esenciales en los inicios de la emergencia, no deteniendo su producción ni pudiendo optar al trabajo remoto. A su vez, los parámetros estimados para los cortes temporales de noviembre 2020 y julio 2021 reflejan un cambio en el signo, donde se deduce que las áreas con mayor proporción de habitantes que trabajan en el rubro industrial mostraron una menor recuperación. Ello podría deberse al incremento del poder adquisitivo de la población en el transcurso de la pandemia, lo que favoreció el cambio a modos privados en desmedro del transporte público.

Por otro lado, las variables proporción de la población que trabaja en el rubro del comercio y proporción de la población que trabaja en el rubro de la construcción, no alcanzaron la significancia estadística en ninguno de los cortes temporales estudiados. Finalmente, la proporción de la población que trabaja en el rubro de la educación es estadísticamente significativa, con un nivel de confianza superior al 85%, en los cortes temporales de mayo, julio y noviembre 2020. Este efecto en el corto y mediano plazo sugiere que las zonas con mayor proporción de habitantes que trabajan en educación tuvieron una menor recuperación de la movilidad de los usuarios de transporte público en la mañana. Lo anterior coincide con lo esperado, teniendo en cuenta el cierre de establecimientos educacionales y la realización de clases en formato no presencial, razón por la cual los trabajadores del rubro ejercieron sus labores desde sus hogares.

5.3. Resultados de los modelos de regresión espacial

Considerando los modelos de regresión lineal como punto de partida, en la presente sección se estimarán modelos de regresión espacial. Si bien las pruebas para detectar autocorrelación espacial, como la I de Moran, ayudan a identificar la existencia de agrupaciones en los residuos del modelo, no permiten conocer el proceso que genera dichas dependencias.

Para abordar este problema se han realizado diferentes pruebas previas donde se exploraron múltiples especificaciones, entre ellas los modelos autorregresivos espaciales de primer orden (SAR), cuyos resultados fueron desfavorables. En función de la significancia estadística obtenida en los parámetros que miden la autocorrelación, se ha definido utilizar dos tipos de modelos: con dependencia espacial en los errores (modelos de error espacial) y con dependencia espacial en variables explicativas (modelos regresivos cruzados o modelos X espacialmente retardados), ambos descritos en el capítulo 2.5.

La estimación de los modelos se ha desarrollado a partir del método de máxima verosimilitud, el cual viene incorporado en el paquete de Stata “Modelos Espaciales Autorregresivos”.

En primer lugar, en la tabla 5.16 se muestran los modelos de regresión espacial estimados por corte temporal y los parámetros obtenidos para cada variable independiente incluida, considerando un proceso autorregresivo espacial del error. A su vez, se entrega el parámetro de correlación de los errores λ , se muestra entre paréntesis el valor del error estándar y en negrilla las variables que resultaron estadísticamente significativas en la modelación, indicando con la simbología */+ el rango en el que se encuentra el p-valor.

Con respecto a la bondad de ajuste de los modelos, dado que R^2 Ajustado no es aplicable, se incorpora el indicador Pseudo R^2 , correspondiente al ratio simple de la varianza de los valores predichos sobre la varianza de los valores observados de la variable dependiente. Se incluyen también los estadísticos AIC y Log-Likelihood. Se observa que con el paso del tiempo el grado de ajuste de los modelos va disminuyendo.

En estos modelos, no existen variables independientes ni explicada con dependencia espacial, por lo que no existen efectos indirectos. Luego, la presencia de errores correlacionados espacialmente no origina efectos spillovers en las variables explicativas.

Se puede notar que, solo en los cortes temporales de mayo y julio 2020 se obtuvo un parámetro de correlación de los errores λ significativo y cercano a 1, lo que confirma la existencia de autocorrelación espacial positiva, sugerida por la I de Moran descrita anteriormente en el capítulo 2.5.

Por otro lado, en los cortes temporales de noviembre 2020, julio y noviembre 2021 el parámetro λ no es significativo, por lo que se descarta la presencia de autocorrelación espacial en los errores para esos modelos.

Tabla 5.16: Estimación modelos de error espacial con indicador $Rec_{pm1,t}$, por corte temporal

Variables	$Rec_{pm1,2}$ Mayo 2020	$Rec_{pm1,3}$ Julio 2020	$Rec_{pm1,4}$ Nov 2020	$Rec_{pm1,5}$ Julio 2021	$Rec_{pm1,6}$ Nov 2021
Nivel de ingreso por hogar bajo	0,019* (0,010)	0,101*** (0,025)	0,293** (0,087)	0,223* (0,102)	0,288* (0,125)
Nivel de ingreso por hogar alto	-0,023+ (0,012)	-0,033 (0,032)	-0,139 (0,120)	-0,121 (0,144)	-0,124 (0,175)
Proporción de la población mujer	0,000 (0,129)	0,368 (0,330)	-0,293 (1,227)	-0,585 (1,465)	-1,014 (1,794)
Proporción de la población con edad entre 15 y 29 años	-0,100 (0,108)	-0,089 (0,281)	-2,194* (0,962)	-2,435* (1,133)	-3,304* (1,391)
Proporción de la población con edad entre 30 y 44 años	0,241* (0,123)	0,519 (0,316)	0,264 (1,130)	0,059 (1,337)	-0,111 (1,641)
Proporción de la población con edad entre 45 y 59 años	0,336+ (0,177)	0,596 (0,458)	-0,705 (1,684)	-1,318 (2,009)	-1,912 (2,464)
Días corridos en cuarentena	0,000 (0,000)	0,000 (0,001)	-	-	-
Proporción de la población en educación formal	-0,063 (0,099)	-0,206 (0,248)	1,052 (0,882)	1,158 (1,046)	1,843 (1,281)
Tasa de motorización por hogar	-0,010 (0,013)	-0,005 (0,035)	-0,133 (0,129)	-0,188 (0,154)	-0,193 (0,188)
Número de ciclovías existentes	-0,000 (0,001)	-0,008* (0,003)	-0,037** (0,012)	-0,041** (0,015)	-0,052** (0,018)
Presencia de estaciones de Metro y Tren	-0,000 (0,005)	0,017 (0,014)	0,169** (0,052)	0,157* (0,062)	0,220** (0,076)
Número de servicios de bus	-0,000 (0,000)	0,001* (0,000)	0,003* (0,001)	0,003* (0,001)	0,003* (0,002)
Proporción de la población que trabaja en el rubro de la industria	0,813* (0,328)	-0,130 (0,871)	-5,701+ (3,222)	-7,093+ (3,787)	-7,805+ (4,623)
Proporción de la población que trabaja en el rubro de la construcción	0,128 (0,273)	-0,286 (0,711)	-1,327 (2,595)	0,138 (3,041)	-1,420 (3,716)
Proporción de la población que trabaja en el rubro del comercio	0,005 (0,155)	-0,450 (0,404)	-1,185 (1,468)	-1,694 (1,730)	-1,707 (2,122)
Proporción de la población que trabaja en el rubro de la educación	-0,274 (0,342)	-1,453 (0,903)	-6,073+ (3,241)	-5,511 (3,822)	-6,080 (4,668)
Constante del modelo	0,070	-0,067	1,511	2,014	2,617
Correlación de los errores espaciales λ	0,933*** (0,065)	0,726** (0,246)	-0,562 (0,757)	-1,145 (0,807)	-1,100 (0,801)
Pseudo R-cuadrado	0,264	0,145	0,140	0,106	0,101
AIC	-1137	-492	384	509	641
LL	587	265	-174	-237	-303
N observaciones	335	327	331	331	331

+: p-valor<0,10 , *: p-valor<0,05, **: p-valor<0,01, ***: p-valor<0,001

Fuente: Elaboración Propia

Con respecto a los valores de los coeficientes estimados y la significancia estadística en los dos primeros cortes temporales, se puede señalar que, en términos generales, se obtienen las mismas conclusiones que con los modelos de regresión lineal múltiple mediante MCO, sólo encontrándose leves diferencias en el p-valor. Esto indica que los modelos se encuentran bien especificados, ya que al corregir por autocorrelación la eficiencia aumenta pero la consistencia no se ve afectada (Hausman, 1978). Ello se verifica comparando las tablas 5.15 y 5.16, donde es posible notar que en los modelos de error espacial se obtienen menores errores estándar.

Dentro de las variables que resultan significativas en el corto plazo, con un nivel de confianza superior al 85%, se encuentran: dummies nivel de ingreso por hogar, proporción de la población adulta (edad entre 30-44 y 45-59 años), número de ciclovías existentes, número de servicios de bus, y proporción de habitantes que trabajan en los rubros de la industria y educación.

El siguiente paso corresponde a la estimación de modelos regresivos cruzados, que se reportan en la Tabla 5.17. En este caso se ha considerado a “Número de ciclovías existentes” y “Número de servicios de bus” como posibles variables explicativas espacialmente retardadas, dada su naturaleza. Es decir, se buscará determinar si la recuperación de la movilidad de los usuarios del transporte público en la mañana, tanto en un área i como en regiones vecinas a i , se ve impactada por el número de ciclovías y el número de servicios de bus existentes en la zona i .

En la tabla 5.17 se presentan los modelos regresivos cruzados de regresión espacial estimados por corte temporal y los parámetros obtenidos para cada variable independiente incluida (efecto directo). Se muestra entre paréntesis el valor del error estándar y en negrilla las variables que resultaron estadísticamente significativas en la modelación, indicando con la simbología */+ el rango en el que se encuentra el p-valor.

Al igual que en los modelos anteriores, la bondad de ajuste se mide a través del indicador Pseudo R^2 , los estadísticos AIC y Log-Likelihood. Se observa que con el paso del tiempo el grado de ajuste de los modelos se reduce.

Se incorporan los parámetros de respuesta θ que miden los efectos de desbordamiento de las variables exógenas espacialmente retardadas (también llamado efecto indirecto o spillover). En la tabla 5.17 se puede notar que, para los primeros cortes temporales de mayo y julio 2020, ambos parámetros θ resultan estadísticamente significativos, lo cual confirma la existencia de retardos espaciales en las variables consideradas.

Tabla 5.17: Estimación modelos regresivos cruzados con indicador $Rec_{pm1,t}$, por corte temporal

Variables	$Rec_{pm1,2}$ Mayo 2020	$Rec_{pm1,3}$ Julio 2020	$Rec_{pm1,4}$ Nov 2020	$Rec_{pm1,5}$ Julio 2021	$Rec_{pm1,6}$ Nov 2021
Nivel de ingreso por hogar bajo	0,019* (0,009)	0,102*** (0,024)	0,276** (0,090)	0,234* (0,109)	0,294* (0,133)
Nivel de ingreso por hogar alto	-0,022+ (0,012)	-0,032 (0,032)	-0,133 (0,119)	-0,112 (0,145)	-0,111 (0,176)
Proporción de la población mujer	0,028 (0,127)	0,349 (0,328)	-0,340 (1,234)	-0,608 (1,497)	-0,962 (1,827)
Proporción de la población con edad entre 15 y 29 años	-0,058 (0,105)	-0,086 (0,275)	-2,153* (0,974)	-2,359* (1,182)	-3,136* (1,443)
Proporción de la población con edad entre 30 y 44 años	0,363** (0,119)	0,642* (0,308)	0,362 (1,159)	0,107 (1,406)	0,088 (1,716)
Proporción de la población con edad entre 45 y 59 años	0,393* (0,173)	0,637 (0,451)	-0,545 (1,700)	-0,871 (2,063)	-1,279 (2,517)
Días corridos en cuarentena	0,000 (0,000)	-0,000 (0,001)			
Proporción de la población en educación formal	-0,142 (0,101)	-0,267 (0,270)	1,343 (0,986)	1,800 (1,197)	2,457+ (1,461)
Tasa de motorización por hogar	-0,004 (0,013)	0,001 (0,035)	-0,056 (0,132)	-0,110 (0,160)	-0,098 (0,195)
Número de ciclovías existentes	0,001 (0,001)	-0,006+ (0,004)	-0,030* (0,013)	-0,039* (0,016)	-0,049* (0,020)
Presencia de estaciones de Metro y Tren	-0,000 (0,005)	0,016 (0,014)	0,160** (0,053)	0,137* (0,065)	0,199* (0,079)
Número de servicios de bus	-0,000 (0,000)	0,001+ (0,000)	0,002+ (0,001)	0,002 (0,001)	0,003+ (0,002)
Proporción de la población que trabaja en el rubro de la industria	0,561+ (0,323)	-0,679 (0,870)	-6,362+ (3,258)	-7,036+ (3,953)	-7,919 (4,824)
Proporción de la población que trabaja en el rubro de la construcción	0,115 (0,268)	-0,378 (0,696)	-0,515 (2,616)	0,762 (3,174)	-0,583 (3,874)
Proporción de la población que trabaja en el rubro del comercio	0,032 (0,153)	-0,372 (0,400)	-1,744 (1,477)	-2,605 (1,792)	-2,819 (2,187)
Proporción de la población que trabaja en el rubro de la educación	-0,330 (0,335)	-1,514+ (0,887)	-5,334 (3,297)	-5,263 (4,000)	-5,814 (4,882)
Constante del modelo	0,033	-0,063	1,197	1,492	1,953
Efecto spillover θ_N CICLOVÍAS	-0,054*** (0,010)	-0,064* (0,027)	-0,148 (0,100)	-0,066 (0,122)	-0,105 (0,148)
Efecto spillover θ_N SERVICIOS BUS	0,003*** (0,001)	0,003* (0,002)	0,011* (0,005)	0,009 (0,007)	0,011 (0,008)
Efecto total Número de ciclovías	-0,049*** (0,009)	-0,065** (0,024)	-0,167+ (0,089)	-0,101 (0,108)	-0,146 (0,132)
Efecto total Número de servicios de bus	0,002*** (0,001)	0,003* (0,001)	0,012* (0,005)	0,011+ (0,006)	0,014+ (0,007)
Pseudo R-cuadrado	0,327	0,161	0,151	0,116	0,110
AIC	-1139	-492	382	510	642
LL	590	266	-172	-236	-302
N observaciones	335	327	331	331	331

+: p-valor<0,10 , *: p-valor<0,05, **: p-valor<0,01, ***: p-valor<0,001

Fuente: Elaboración Propia

Sin embargo, en los cortes temporales de noviembre 2020, julio y noviembre 2021 los parámetros θ pierden significancia estadística, por lo que se descarta la existencia de dependencia espacial de las variables explicativas para dichos modelos.

El efecto spillover de la variable número de ciclovías existentes es negativo. Esto significa que ante una mayor presencia de ciclovías en la zona i , la recuperación de la movilidad de los usuarios de transporte público en la mañana en sectores aledaños a la zona i se verá reducida.

De forma similar, se observa que el efecto spillover de la variable número de servicios de bus obtiene signo positivo. Esto quiere decir que una mayor cobertura de los servicios de bus en el área i favorece la recuperación del transporte público en zonas vecinas del área i .

Adicionalmente, en la tabla 5.17 se muestra el efecto total de las variables “Número de ciclovías existentes” y “Número de servicios de bus” sobre la variable explicada, el cual consolida ambos efectos, directos e indirectos. Este representa cómo un cambio marginal de la variable explicativa en un área particular impacta a la recuperación del transporte público de la región misma (efecto directo) y de zonas vecinas a ella (efecto indirecto o spillover).

En el caso del número de ciclovías, el impacto total es negativo, es decir, un aumento del número de ciclovías en la zona i implicará que la recuperación de la movilidad de los usuarios de transporte público en la mañana, tanto en la misma zona i como en sectores aledaños, se verá desfavorecida. Este resultado sugiere un efecto de sustitución, donde la construcción de infraestructura vial especializada para ciclos llevaría a las personas a preferir alternativas de transporte individuales en desmedro de medios masivos como el transporte público.

Por otro lado, el efecto total de la variable número de servicios de bus es positivo. Luego, un incremento en el número de recorridos de bus en el área i contribuye en la recuperación de la movilidad del área misma y de zonas vecinas al área i . Esto se explica por el hecho de que las áreas con redes más densas, cuya cobertura de servicios de bus es mayor, ofrecen una mejor accesibilidad y conectividad a los pasajeros, favoreciendo al transporte público.

Sobre los valores de los parámetros estimados y su significancia estadística en los cortes temporales del inicio de la pandemia, se obtienen resultados similares a los arrojados por los modelos de error espacial, identificándose diferencias en el p-valor.

Con ello, las variables estadísticamente significativas en el corte plazo, con un nivel de confianza mayor al 90%, son: dummies nivel de ingreso por hogar, proporción de la población adulta (edad entre 30-44 y 45-59 años), número de ciclovías existentes, número de servicios de bus, y proporción de habitantes que trabajan en los rubros de la industria y educación.

5.4. Análisis comparativo de modelos

Con el objetivo de identificar las principales diferencias obtenidas a partir de las técnicas usadas y definir cuáles de los modelos estudiados resultan representativos de cada corte temporal, se realiza el siguiente análisis comparativo. Para ello, en las tablas que se muestran a continuación se contrastan, por corte temporal, los parámetros estimados a partir de los modelos de regresión lineal múltiple y de regresión espacial.

Respecto al primer corte temporal, se observa que en los tres modelos estimados las variables explicativas que alcanzan significancia estadística son las mismas. Los valores de sus coeficientes y signos tampoco muestran diferencias considerables entre las técnicas usadas. Se nota también que los parámetros que indican la existencia de dependencia espacial son significativos con un nivel de confianza del 99%, lo cual descarta el uso de MCO para este caso.

Tabla 5.18: Comparación de parámetros modelos de regresión lineal y espacial, corte temporal mayo 2020

Variables	Coef. regresión lineal	Coef. regresión error espacial	Coef. regresión espacial cruzada
Nivel de ingreso por hogar bajo	0,027**	0,019*	0,019*
Nivel de ingreso por hogar alto	-0,023⁺	-0,023⁺	-0,022⁺
Proporción de la población mujer	0,036	0,000	0,028
Proporción de la población con edad entre 15 y 29 años	-0,085	-0,100	-0,058
Proporción de la población con edad entre 30 y 44 años	0,304*	0,241*	0,363**
Proporción de la población con edad entre 45 y 59 años	0,395*	0,336⁺	0,393*
Días corridos en cuarentena	0,000	0,000	0,000
Proporción de la población en educación formal	-0,096	-0,063	-0,142
Tasa de motorización por hogar	-0,018	-0,010	-0,004
Número de ciclovías existentes	-0,001	-0,000	0,001
Presencia de estaciones de Metro y Tren	-0,001	-0,000	-0,000
Número de servicios de bus	0,000	-0,000	-0,000
Proporción de la población que trabaja en el rubro de la industria	0,841*	0,813*	0,561⁺
Proporción de la población que trabaja en el rubro de la construcción	-0,082	0,128	0,115
Proporción de la población que trabaja en el rubro del comercio	0,043	0,005	0,032
Proporción de la población que trabaja en el rubro de la educación	-0,553	-0,274	-0,330
Correlación de los errores espaciales λ	-	0,933**	-
Efecto spillover θ_N CICLOVÍAS	-	-	-0,054***
Efecto spillover θ_N SERVICIOS BUS	-	-	0,003***
Efecto total número de ciclovías	-	-	-0,049***
Efecto total número de servicios de bus	-	-	0,002***
R-cuadrado o Pseudo R-cuadrado	0,269	0,264	0,327
AIC	-1118	-1137	-1139
LL	576	587	590

⁺: p – valor < 0,10, * : p – valor < 0,05, ** : p – valor < 0,01, *** : p – valor < 0,001

Fuente: Elaboración Propia

Por otro lado, al comparar el modelo de error espacial con el regresivo cruzado se encuentran diferencias en la bondad de ajuste, resultando levemente superior en el segundo de ellos. Luego, para caracterizar la recuperación de la movilidad de los usuarios de transporte público en los inicios de la pandemia por COVID-19 e identificar qué factores la explican, se considerará el modelo espacialmente retardado en X.

Algo similar ocurre con el segundo corte temporal, cuya comparación se muestra en la tabla 5.19. En los tres modelos estimados, las variables estadísticamente significativas son prácticamente las mismas, pero difieren en el p-valor. Los signos y valores de sus coeficientes tampoco tienen diferencias importantes entre las técnicas usadas. Esto indica que los modelos se encuentran bien especificados, ya que al corregir por autocorrelación la eficiencia aumenta pero la consistencia no se ve afectada (Hausman, 1978).

Tabla 5.19: Comparación de parámetros modelos de regresión lineal y espacial, corte temporal julio 2020

Variables	Coef. regresión lineal	Coef. regresión error espacial	Coef. regresión espacial cruzada
Nivel de ingreso por hogar bajo	0,110**	0,101***	0,102***
Nivel de ingreso por hogar alto	-0,031	-0,033	-0,032
Proporción de la población mujer	0,355	0,368	0,349
Proporción de la población con edad entre 15 y 29 años	-0,109	-0,089	-0,086
Proporción de la población con edad entre 30 y 44 años	0,560+	0,519	0,642*
Proporción de la población con edad entre 45 y 59 años	0,648	0,596	0,637
Días corridos en cuarentena	0,000	0,000	-0,000
Proporción de la población en educación formal	-0,202	-0,206	-0,267
Tasa de motorización por hogar	-0,014	-0,005	0,001
Número de ciclovías existentes	-0,009*	-0,008*	-0,006+
Presencia de estaciones de Metro y Tren	0,015	0,017	0,016
Número de servicios de bus	0,001*	0,001*	0,001+
Proporción de la población que trabaja en el rubro de la industria	-0,261	-0,130	-0,679
Proporción de la población que trabaja en el rubro de la construcción	-0,568	-0,286	-0,378
Proporción de la población que trabaja en el rubro del comercio	-0,359	-0,450	-0,372
Proporción de la población que trabaja en el rubro de la educación	-1,761+	-1,453	-1,514+
Correlación de los errores espaciales λ	-	0,726**	-
Efecto spillover θ_N CICLOVÍAS	-	-	-0,064*
Efecto spillover θ_N SERVICIOS BUS	-	-	0,003*
Efecto total número de ciclovías	-	-	-0,065**
Efecto total número de servicios de bus	-	-	0,003*
R-cuadrado o Pseudo R-cuadrado	0,146	0,145	0,161
AIC	-492	-492	-492
LL	263	265	266

+ : p – valor < 0,10 , * : p – valor < 0,05, ** : p – valor < 0,01, *** : p – valor < 0,001

Fuente: Elaboración Propia

En este caso, el indicador de correlación de los errores λ y los parámetros del efecto spillover θ son significativos al 95%, por lo que también se descarta el uso del modelo de regresión lineal mediante MCO.

Para determinar cuál de los modelos restantes se considerará como representativo del fenómeno en el segundo corte temporal de julio 2020, se utilizan nuevamente las medidas de bondad de ajuste. En la tabla 5.19.se nota que ambos modelos obtienen un ajuste similar, siendo sutilmente mayor en el modelo de regresión espacial cruzada.

Con respecto al corte temporal de noviembre 2020, se puede observar que el parámetro que mide la dependencia espacial de los errores pierde significancia estadística.

Tabla 5.20: Comparación de parámetros modelos de regresión lineal y espacial, corte temporal nov 2020

Variables	Coef. regresión lineal	Coef. regresión error espacial	Coef. regresión espacial cruzada
Nivel de ingreso por hogar bajo	0,287**	0,293**	0,276**
Nivel de ingreso por hogar alto	-0,132	-0,139	-0,133
Proporción de la población mujer	-0,217	-0,293	-0,340
Proporción de la población con edad entre 15 y 29 años	-2,100*	-2,194*	-2,153*
Proporción de la población con edad entre 30 y 44 años	0,312	0,264	0,362
Proporción de la población con edad entre 45 y 59 años	-0,653	-0,705	-0,545
Proporción de la población en educación formal	0,970	1,052	1,343
Tasa de motorización por hogar	-0,118	-0,133	-0,056
Número de ciclovías existentes	-0,037**	-0,037**	-0,030*
Presencia de estaciones de Metro y Tren	0,171**	0,169**	0,160**
Número de servicios de bus	0,002*	0,003*	0,002⁺
Proporción de la población que trabaja en el rubro de la industria	-5,257⁺	-5,701⁺	-6,362⁺
Proporción de la población que trabaja en el rubro de la construcción	-0,988	-1,327	-0,515
Proporción de la población que trabaja en el rubro del comercio	-1,394	-1,185	-1,744
Proporción de la población que trabaja en el rubro de la educación	-5,812	-6,073⁺	-5,334
Correlación de los errores espaciales λ	-	-0,562	-
Efecto spillover $\theta_{N \text{ CICLOVÍAS}}$	-	-	-0,148
Efecto spillover $\theta_{N \text{ SERVICIOS BUS}}$	-	-	0,011*
Efecto total número de ciclovías	-	-	-0,167⁺
Efecto total número de servicios de bus	-	-	0,012*
R-cuadrado o Pseudo R-cuadrado	0,140	0,140	0,151
AIC	381	384	382
LL	-174	-174	-172

+ : p – valor < 0,10 , * : p – valor < 0,05, ** : p – valor < 0,01, *** : p – valor < 0,001

Fuente: Elaboración Propia

A su vez, el efecto spillover de la variable número de ciclovías existentes tampoco resulta significativo desde este corte temporal en adelante, mientras que el de la variable número de servicios de bus aún tiene significancia estadística.

Por lo tanto, dado que la dependencia espacial ha perdido relevancia en el corte temporal analizado, se considerará el modelo de regresión lineal para caracterizar los factores que contribuyen o no en la recuperación de la movilidad de los usuarios de transporte público en el mediano plazo del desarrollo de la emergencia sanitaria. Se debe recordar que para este corte temporal se efectuó una regresión robusta mediante MCG, la que fue descrita en el capítulo 5.2.

Finalmente, en los comparativos de los cortes temporales restantes que se muestran en las tablas 5.21 y 5.22 (julio y noviembre 2021), se nota que tanto el indicador de correlación de los errores λ como los parámetros del efecto spillover θ no obtienen significancia estadística.

Tabla 5.21: Comparación de parámetros modelos de regresión lineal y espacial, corte temporal julio 2021

Variables	Coef. regresión lineal	Coef. regresión error espacial	Coef. regresión espacial cruzada
Nivel de ingreso por hogar bajo	0,230*	0,223*	0,234*
Nivel de ingreso por hogar alto	-0,110	-0,121	-0,112
Proporción de la población mujer	-0,411	-0,585	-0,608
Proporción de la población con edad entre 15 y 29 años	-2,236⁺	-2,435*	-2,359*
Proporción de la población con edad entre 30 y 44 años	0,210	0,059	0,107
Proporción de la población con edad entre 45 y 59 años	-1,045	-1,318	-0,871
Proporción de la población en educación formal	1,028	1,158	1,800
Tasa de motorización por hogar	-0,165	-0,188	-0,110
Número de ciclovías existentes	-0,042**	-0,041**	-0,039*
Presencia de estaciones de Metro y Tren	0,157*	0,157*	0,137*
Número de servicios de bus	0,002⁺	0,003*	0,002
Proporción de la población que trabaja en el rubro de la industria	-6,324	-7,093⁺	-7,036⁺
Proporción de la población que trabaja en el rubro de la construcción	0,610	0,138	0,762
Proporción de la población que trabaja en el rubro del comercio	-2,121	-1,694	-2,605
Proporción de la población que trabaja en el rubro de la educación	-5,301	-5,511	-5,263
Correlación de los errores espaciales λ	-	-1,145	-
Efecto spillover θ_N CICLOVÍAS	-	-	-0,066
Efecto spillover θ_N SERVICIOS BUS	-	-	0,009
Efecto total número de ciclovías	-	-	-0,101
Efecto total número de servicios de bus	-	-	0,011⁺
R-cuadrado o Pseudo R-cuadrado	0,107	0,106	0,116
AIC	508	509	510
LL	-238	-237	-236

+ : p – valor < 0,10 , * : p – valor < 0,05, ** : p – valor < 0,01, *** : p – valor < 0,001

Fuente: Elaboración Propia

Tabla 5.22: Comparación de parámetros modelos de regresión lineal y espacial, corte temporal nov 2021

Variables	Coef. regresión lineal	Coef. regresión error espacial	Coef. regresión espacial cruzada
Nivel de ingreso por hogar bajo	0,294*	0,288*	0,294*
Nivel de ingreso por hogar alto	-0,109	-0,124	-0,111
Proporción de la población mujer	-0,744	-1,014	-0,962
Proporción de la población con edad entre 15 y 29 años	-3,008*	-3,304*	-3,136*
Proporción de la población con edad entre 30 y 44 años	0,167	-0,111	0,088
Proporción de la población con edad entre 45 y 59 años	-1,470	-1,912	-1,279
Proporción de la población en educación formal	1,639	1,843	2,457+
Tasa de motorización por hogar	-0,167	-0,193	-0,098
Número de ciclovías existentes	-0,053**	-0,052**	-0,049*
Presencia de estaciones de Metro y Tren	0,220**	0,220**	0,199*
Número de servicios de bus	0,003+	0,003*	0,003+
Proporción de la población que trabaja en el rubro de la industria	-6,935	-7,805+	-7,919
Proporción de la población que trabaja en el rubro de la construcción	-0,865	-1,420	-0,583
Proporción de la población que trabaja en el rubro del comercio	-2,272	-1,707	-2,819
Proporción de la población que trabaja en el rubro de la educación	-5,993	-6,080	-5,814
Correlación de los errores espaciales λ	-	-1,100	-
Efecto spillover θ_N CICLOVÍAS	-	-	-0,105
Efecto spillover θ_N SERVICIOS BUS	-	-	0,011
Efecto total número de ciclovías	-	-	-0,146
Efecto total número de servicios de bus	-	-	0,014+
R-cuadrado o Pseudo R-cuadrado	0,102	0,101	0,110
AIC	639	641	642
LL	-304	-303	-302

+ : p – valor < 0,10 , * : p – valor < 0,05, ** : p – valor < 0,01, *** : p – valor < 0,001

Fuente: Elaboración Propia

Es por lo que se utilizará el modelo de regresión lineal clásico mediante MCO para describir los factores que impactarán en la recuperación de la movilidad de los usuarios de transporte público, en el mediano y largo plazo de la pandemia.

5.5. Modelos finales

Los modelos finales estimados para cada corte temporal se exponen en la tabla 5.23, los cuales permiten caracterizar a los factores que contribuyen o no en la recuperación de la movilidad de los usuarios de transporte público en la mañana. Como se señaló anteriormente, para los cortes temporales representativos del inicio de la pandemia, se considera la especificación que aborda la existencia de dependencia espacial, concretamente, el modelo espacialmente retardado en X cuya bondad de ajuste resulta superior a la del modelo de error espacial. Por su parte, para los cortes temporales que representan el mediano y largo plazo de la emergencia sanitaria, se utiliza el modelo de regresión lineal clásico mediante MCO, efectuando una regresión lineal con errores estándares robustos en caso de que amerite.

Tabla 5.23: Modelos finales estimados, con indicador $Rec_{pm1,t}$, por corte temporal

Variables	$Rec_{pm1,2}$ Mayo 2020	$Rec_{pm1,3}$ Julio 2020	$Rec_{pm1,4}$ Nov 2020	$Rec_{pm1,5}$ Julio 2021	$Rec_{pm1,6}$ Nov 2021
Nivel de ingreso por hogar bajo	0,019* (0,009)	0,102*** (0,024)	0,287* (0,143)	0,230* (0,111)	0,294* (0,135)
Nivel de ingreso por hogar alto	-0,022+ (0,012)	-0,032 (0,032)	-0,132 (0,092)	-0,110 (0,149)	-0,109 (0,182)
Proporción de la población mujer	0,028 (0,127)	0,349 (0,328)	-0,217 (0,858)	-0,411 (1,537)	-0,744 (1,875)
Proporción de la población con edad entre 15 y 29 años	-0,058 (0,105)	-0,086 (0,275)	-2,100** (0,765)	-2,236+ (1,215)	-3,008* (1,482)
Proporción de la población con edad entre 30 y 44 años	0,363** (0,119)	0,642* (0,308)	0,312 (1,012)	0,210 (1,437)	0,167 (1,753)
Proporción de la población con edad entre 45 y 59 años	0,393* (0,173)	0,637 (0,451)	-0,653 (1,382)	-1,045 (2,122)	-1,470 (2,589)
Días corridos en cuarentena	0,000 (0,000)	-0,000 (0,001)	-	-	-
Proporción de la población en educación formal	-0,142 (0,101)	-0,267 (0,270)	0,970 (0,813)	1,028 (1,104)	1,639 (1,347)
Tasa de motorización por hogar	-0,004 (0,013)	0,001 (0,035)	-0,118 (0,100)	-0,165 (0,160)	-0,167 (0,195)
Número de ciclovías existentes	-0,049*** (0,009)	-0,065** (0,024)	-0,037** (0,012)	-0,042** (0,016)	-0,053** (0,019)
Presencia de estaciones de Metro y Tren	-0,000 (0,005)	0,016 (0,014)	0,171** (0,060)	0,157* (0,065)	0,220** (0,080)
Número de servicios de bus	0,002*** (0,001)	0,003* (0,001)	0,002* (0,001)	0,002+ (0,001)	0,003+ (0,002)
Proporción de la población que trabaja en el rubro de la industria	0,561+ (0,323)	-0,679 (0,870)	-5,257+ (2,729)	-6,324 (3,998)	-6,935 (4,877)
Proporción de la población que trabaja en el rubro de la construcción	0,115 (0,268)	-0,378 (0,696)	-0,988 (2,678)	0,610 (3,239)	-0,865 (3,951)
Proporción de la población que trabaja en el rubro del comercio	0,032 (0,153)	-0,372 (0,400)	-1,394 (1,030)	-2,121 (1,825)	-2,272 (2,227)
Proporción de la población que trabaja en el rubro de la educación	-0,330 (0,335)	-1,514+ (0,887)	-5,812+ (3,362)	-5,301 (4,082)	-5,993 (4,979)
Constante del modelo	0,033	-0,063	1,431	1,813	2,316
R-cuadrado o Pseudo R-cuadrado	0,327	0,161	0,140	0,107	0,102

+: p-valor<0,10 , *: p-valor<0,05, **: p-valor<0,01, ***: p-valor<0,001

La columna " $Rec_{pm1,4}$ Nov 2020" muestra errores estándar robustos entre paréntesis

Fuente: Elaboración Propia

5.6. Importancia relativa de los parámetros

Con la finalidad de valorar la importancia relativa de cada variable explicativa respecto a la variable estudiada y con ello categorizarlas, se utilizarán los coeficientes de regresión estandarizados, los cuales se estiman a través del software Stata y cuyo método de obtención se describe en el capítulo 2.5. Es útil recordar que estos se basan en puntuaciones típicas Z , con lo que las escalas de las variables explicativas se vuelven irrelevantes, permitiendo efectuar comparaciones entre ellas. En general, mientras mayor sea el valor del coeficiente estandarizado (en valor absoluto), más peso tiene la respectiva variable independiente sobre la recuperación de la movilidad de los usuarios de transporte público en la mañana. En la tabla siguiente se muestran los resultados obtenidos para cada corte temporal modelado.

Tabla 5.24: Coeficientes estandarizados modelos de regresión con indicador $Rec_{pm1,t}$, por corte temporal

Variables	$Rec_{pm1,2}$ Mayo 2020	$Rec_{pm1,3}$ Julio 2020	$Rec_{pm1,4}$ Nov 2020	$Rec_{pm1,5}$ Julio 2021	$Rec_{pm1,6}$ Nov 2021
Nivel de ingreso por hogar bajo	0,144	0,255	0,175	0,118	0,124
Nivel de ingreso por hogar alto	-0,134	-0,081	-0,090	-0,063	-0,051
Proporción de la población mujer	0,020	0,086	-0,014	-0,022	-0,033
Proporción de la población con edad entre 15 y 29 años	-0,052	-0,029	-0,146	-0,131	-0,145
Proporción de la población con edad entre 30 y 44 años	0,275	0,218	0,032	0,018	0,023
Proporción de la población con edad entre 45 y 59 años	0,197	0,139	-0,037	-0,050	-0,058
Días corridos en cuarentena	0,063	0,011	-	-	-
Proporción de la población en educación formal	-0,068	-0,062	0,079	0,070	0,092
Tasa de motorización por hogar	-0,126	-0,045	-0,097	-0,115	-0,095
Número de ciclovías existentes	-0,058	-0,167	-0,182	-0,175	-0,183
Presencia de estaciones de Metro y Tren	-0,009	0,063	0,193	0,150	0,172
Número de servicios de bus	0,012	0,167	0,133	0,112	0,116
Proporción de la población que trabaja en el rubro de la industria	0,157	-0,021	-0,110	-0,112	-0,101
Proporción de la población que trabaja en el rubro de la construcción	-0,022	-0,067	-0,031	0,016	-0,019
Proporción de la población que trabaja en el rubro del comercio	0,017	-0,063	-0,065	-0,084	-0,074
Proporción de la población que trabaja en el rubro de la educación	-0,158	-0,217	-0,189	-0,145	-0,135

Fuente: Elaboración Propia

A partir de la relevancia de cada variable y la significancia estadística analizada en los acápites anteriores, en la tabla 5.25 se presentan los factores identificados como influyentes en la recuperación de la movilidad de los usuarios de transporte público en la mañana. Estos son agrupados por cada categoría de variable, impacto (corto, mediano o largo plazo) y ordenados de manera decreciente en importancia.

Tabla 5.25: Variables significativas por corte temporal, agrupadas por tipo y en orden decreciente de importancia

Categoría	Efecto inmediato	Efecto corto plazo	Efecto mediano plazo		Efecto largo plazo
	Mayo 2020	Julio 2020	Noviembre 2020	Julio 2021	Noviembre 2021
Sociodemográficas	Proporción de la población con edad entre 30 y 44 años	Nivel de ingreso por hogar bajo	Nivel de ingreso por hogar bajo	Proporción de la población con edad entre 15 y 29 años	Proporción de la población con edad entre 15 y 29 años
	Proporción de la población con edad entre 45 y 59 años	Proporción de la población con edad entre 30 y 44 años	Proporción de la población con edad entre 15 y 29 años	Nivel de ingreso por hogar bajo	Nivel de ingreso por hogar bajo
	Nivel de ingreso por hogar bajo	-	Nivel de ingreso por hogar alto	-	-
	Nivel de ingreso por hogar alto	-	-	-	-
Accesibilidad al transporte	-	Número de ciclovías existentes	Presencia de estaciones de Metro y Tren	Número de ciclovías existentes	Número de ciclovías existentes
	-	Número de servicios de bus	Número de ciclovías existentes	Presencia de estaciones de Metro y Tren	Presencia de estaciones de Metro y Tren
	-	-	Número de servicios de bus	Número de servicios de bus	Número de servicios de bus
Trabajo	Proporción de la población que trabaja en el rubro de la industria	Proporción de la población que trabaja en el rubro de la educación	Proporción de la población que trabaja en el rubro de la educación	Proporción de la población que trabaja en el rubro de la industria	-
	-	-	Proporción de la población que trabaja en el rubro de la industria	-	-

Fuente: Elaboración Propia

Capítulo 6: Conclusiones y Recomendaciones

6.1. Conclusiones

En la presente tesis se ha estudiado el impacto de la pandemia por COVID-19 en la movilidad de los usuarios del transporte público e identificado factores relacionados con la reducción de la cantidad de pasajeros, en la ciudad de Santiago de Chile. Para ello, se utilizaron datos de transacciones de pago mediante tarjetas inteligentes, que entregan información de la operación del sistema durante seis semanas no consecutivas, en los años 2020 y 2021, representativas de diferentes escenarios de la crisis sanitaria.

Con respecto al estudio de los efectos de la pandemia, se aplican primero técnicas estadísticas y de visualización de datos para caracterizar de manera global el comportamiento del transporte público. Se muestran perfiles diarios y horarios de la demanda, desagregados por modo de transporte. Adicionalmente, se observa la evolución temporal de los indicadores de movilidad de los usuarios del sistema en el desarrollo de la emergencia sanitaria y se presentan estadísticas espaciales de los viajes.

El análisis agregado de los datos pasivos muestra cambios en los patrones de movilidad y en el comportamiento de los usuarios del transporte público. En primer lugar, se observa una caída en el número de viajes y usuarios del sistema, en comparación con los niveles existentes previo a la pandemia. Si bien se registra una recuperación gradual de los indicadores, a fines del año 2021 no se ha logrado alcanzar la demanda observada en la situación base, registrándose a noviembre 2021 un 23% menos de transacciones y tarjetas activas en día laboral. A la vez, se evidencia una mayor recuperación de la movilidad durante los fines de semana. Estos resultados coinciden con lo identificado en la literatura.

Se destaca que en el transcurso de la emergencia sanitaria se generó un incremento en la proporción de tarjetas usadas para realizar un viaje diario, en desmedro de las tarjetas con tres o más viajes por día. Por otro lado, los resultados obtenidos arrojan una leve disminución en la frecuencia de viaje semanal promedio, junto con una reducción de la proporción de usuarios frecuentes del transporte público. Con respecto a la periodicidad de los pasajeros, sólo el 1,1% de las tarjetas observadas en alguno de los seis cortes temporales realizó viajes en cada uno de los periodos analizados.

Finalmente, se detectaron diferencias espaciales en la recuperación de la movilidad de los usuarios del transporte público. Se identifica una caída sostenida, con niveles de demanda inferiores a los de la situación inicial en algunas áreas de la ciudad (Santiago Centro, Puente Alto, Lo Prado y Las Condes), mientras que en otros sectores se registraron valores superiores a los observados previo a la pandemia (San Bernardo y Macul).

Respecto al análisis de los factores que explican el impacto de la pandemia por COVID-19 sobre la cantidad de pasajeros del transporte público, este se efectuó a partir de la estimación de modelos de regresión multivariada. La modelación fue abordada para cinco cortes temporales que reflejan distintos momentos de la emergencia sanitaria en la ciudad de Santiago, con diferentes grados de confinamiento, restricciones de desplazamiento impuestas por las autoridades y niveles de movilidad. Estos fueron contrastados con la situación de referencia de marzo 2020. Por lo tanto, se utilizó la información espacio temporal de los datos pasivos registrados en las mismas semanas antes estudiadas, y se contempló una desagregación geográfica a nivel de distrito censal.

Los modelos estimados incluyeron como variable dependiente a la razón entre el número de usuarios observados en un corte temporal representativo de la pandemia y los pasajeros registrados en la situación inicial, previo a la crisis sanitaria. Se consideraron sólo a los viajeros que realizaron su primera validación del día en la mañana, con origen del viaje en el distrito censal donde se ubica la zona de residencia inferida. Sobre las variables independientes, estas fueron construidas y agrupadas en cinco categorías: sociodemográficas, asociadas a las cuarentenas, presencia de estudiantes, accesibilidad al transporte y existencia de trabajadores de ciertos rubros.

Se concluye que es factible determinar las variables que afectan en la no recuperación de la movilidad de los usuarios del transporte público en la mañana a partir de modelos estadísticos de regresión multivariada. Por tanto, el objetivo general del trabajo de investigación se cumple.

Para esto, se verificaron los supuestos requeridos para usar mínimos cuadrados ordinarios. En aquellos modelos que se detectó la existencia de heterocedasticidad se realizó una regresión lineal con errores estándares robustos. Por su parte, en los casos donde se encontró la presencia de autocorrelación espacial, se aplicó la técnica de regresión espacial para corregir dicho efecto. Específicamente se estimaron modelos de error espacial y modelos espacialmente retardados en las variables explicativas “número de ciclovías existentes” y “número de servicios de bus”. Adicionalmente se identificó si las variables independientes contribuyen a aumentar o disminuir la recuperación de la movilidad y se cuantifica su efecto.

El nivel de ingreso bajo por hogar resultó ser estadísticamente significativo en cada corte temporal estudiado y de gran relevancia entre las variables que inciden en la recuperación de la movilidad de los usuarios del transporte público en la mañana. Se observa que en áreas con bajos ingresos la cantidad de pasajeros se asimila más a los valores registrados en la situación inicial, en comparación con las zonas de nivel de ingreso medio.

Por otro lado, los resultados muestran un efecto inmediato en variables que obtienen significancia estadística solo en los primeros cortes temporales. Estas son la proporción de población con edad entre 30 y 44 años, proporción de población con edad entre 44 y 59 años, proporción de la población que trabaja en el rubro de la educación y nivel de ingreso alto por hogar. Se detecta que en áreas con mayor proporción de población adulta la recuperación de la movilidad

de los usuarios del transporte público es mayor. Lo anterior va en línea con que en los inicios de la crisis sanitaria si bien se restringieron fuertemente los desplazamientos, muchas personas continuaron trabajando en rubros esenciales o donde el teletrabajo aún no era impulsado.

Por su parte, zonas con mayor proporción de habitantes que trabajan en educación tienen una menor recuperación, lo cual coincide con el cierre de establecimientos educacionales y el desarrollo de clases no presenciales, favoreciendo las labores de manera remota en los trabajadores del rubro. Con respecto al nivel de ingreso alto por hogar, se obtiene que en sectores con mayores recursos el impacto sobre la recuperación de la movilidad de los usuarios de transporte público es menor que en zonas con nivel de ingreso medio.

Los hallazgos relacionados con el ingreso por hogar son consistentes con los identificados en la literatura, donde los usuarios de transporte público con menores ingresos están cautivos al sistema y por lo general, trabajan en rubros que requieren labores presenciales. Por el contrario, usuarios con ingresos altos cuentan con mayor acceso a otros modos de transporte y suelen desempeñarse en rubros que permiten el trabajo remoto.

Las variables número de ciclovías existentes, número de servicios de bus, presencia de estaciones de metro y tren, y proporción de la población con edad entre 15 y 29 años adquieren significancia estadística con el transcurso de la pandemia. Los parámetros estimados señalan que las áreas con mayor cantidad de ciclovías existentes contribuyen a disminuir la recuperación de los usuarios, tanto en la misma zona como en sectores aledaños a ella (efecto spillover). Esto se debe a los cambios en la elección de modo derivados de la emergencia sanitaria, donde las personas tienden a preferir modos individuales y evitar aglomeraciones.

Por el contrario, en sectores con una mayor cantidad de servicios de bus se favorece la recuperación de la movilidad de los usuarios, tanto en el área en cuestión como en zonas vecinas (efecto spillover). A la vez, sectores con más presencia de estaciones de metro y tren contribuyen en incrementar la cantidad de pasajeros. Esto se debe a que dichas áreas poseen una mayor conectividad, cobertura y accesibilidad al transporte público. Finalmente, en sectores donde la proporción de la población joven es más alta la recuperación de la movilidad se ve reducida, en concordancia con los menores desplazamientos efectuados por este grupo etario debido a la no realización de clases presenciales en establecimientos educacionales.

El presente trabajo identifica variables que son claves para explicar la disminución de la demanda en el transporte público producto de la pandemia. Logra reafirmar diversos hallazgos encontrados en otros estudios, los cuales utilizan datos de un solo corte temporal o bien, de series de tiempo más cortas. Por lo tanto, una de las principales contribuciones de este trabajo es el análisis de la evolución de la demanda en varios cortes temporales, abarcando un periodo de prácticamente dos años.

A su vez, los resultados obtenidos en esta tesis tienen utilidad en la generación de medidas de planificación y gestión enfocadas en mejorar la operación del transporte público en la ciudad de Santiago, afrontar los desafíos impuestos por la pandemia de COVID-19, revertir la percepción de modo riesgoso y reconvertirlo en uno atractivo para las personas.

Si bien existen diversos estudios fuera de Chile que tratan de cuantificar el impacto de la crisis sanitaria y explicar las causas de la disminución sostenida en el número de pasajeros, esta investigación es una de las primeras en el país en determinar los factores que inciden significativamente en la recuperación de la movilidad de los usuarios. Por ende, los hallazgos que se presentan pueden ayudar a las entidades reguladoras, autoridades y empresas operadoras del sistema, a comprender los motivos y patrones de los cambios en el número de usuarios durante la pandemia, y analizar su posible proyección en el largo plazo.

En resumen, a continuación, se presenta una lista de las variables explicativas que favorecen la recuperación de la movilidad de los usuarios del transporte público en la mañana.

- Nivel de ingreso por hogar bajo
- Proporción de la población con edad entre 30 y 44 años
- Proporción de la población con edad entre 45 y 59 años
- Presencia de estaciones de metro y tren
- Número de servicios de bus

Por otro lado, los factores que desfavorecen la recuperación de la cantidad de pasajeros del transporte público en la mañana son los siguientes.

- Nivel de ingreso por hogar alto
- Proporción de la población con edad entre 15 y 29 años
- Número de ciclovías existentes
- Proporción de la población que trabaja en el rubro de la educación

6.2. Recomendaciones

Los resultados obtenidos en esta investigación permiten generar una serie de propuestas a ser consideradas por el regulador del sistema y las empresas operadoras, enfocadas en reestructuraciones futuras del diseño, operación de la red e infraestructura, cuya finalidad es recuperar los niveles de demanda de pasajeros existentes previo a la pandemia por COVID-19. Dichas recomendaciones se listan a continuación:

- Dado que en zonas con mayor cantidad de servicios de buses, la recuperación de la movilidad de los usuarios del transporte público se ve favorecida, se sugiere evaluar y aumentar, en caso que se requiera, los servicios de buses en áreas poco densas. Si bien la oferta del transporte público se ajusta a partir de la demanda existente, los resultados antes

presentados muestran que las zonas con mejor accesibilidad logran recapturar una mayor cantidad de usuarios. Por ende, se propone incrementar el número de recorridos en áreas con deficiente acceso al sistema, por lo general ubicadas en sectores periféricos que dependen más del uso del transporte público, velando por satisfacer la demanda post pandemia.

- Teniendo en cuenta que en áreas con mayor cantidad de ciclovías existentes, la recuperación de la movilidad se ha visto desfavorecida, se sugiere fomentar la intermodalidad entre el transporte público y los modos no motorizados, en búsqueda de reducir la fuga de la demanda a otros medios. Considerando el auge que han tenido los ciclos durante la crisis sanitaria y la mayor construcción de infraestructura especializada, se propone implementar políticas que permitan complementar ambos modos de transporte. Entre ellas se encuentra evaluar la integración de la bicicleta en los medios de transporte público, construir más estacionamientos en puntos estratégicos de la red con alta transferencia de demanda y estudiar la posibilidad de llevar ciclos al interior del transporte público, estableciendo protocolos y un número máximo por vehículo.
- Se recomienda priorizar el transporte público y promover su uso a partir de una mayor inversión en infraestructura, que mejore la accesibilidad de las personas al sistema. El presente trabajo muestra que en áreas con presencia de estaciones de metro y tren la recuperación de los usuarios se ve favorecida. Por tanto, se sugiere desarrollar proyectos que permitan extender la red del transporte público en la ciudad de Santiago, poniendo énfasis en la densificación de sectores con conectividad deficiente, y velar por su materialización en el mediano plazo.
- Considerando que la recuperación de la movilidad de los usuarios del transporte público se ha visto potenciada en zonas con bajos ingresos, se propone evaluar la posibilidad de rebajar la tarifa a personas con menores recursos. Implementar una tarifa diferenciada permitiría recapturar una mayor demanda y fomentar el uso en sectores que de por sí ya utilizan frecuentemente el transporte público, además de incentivar la disminución de la evasión al pago del pasaje.

Adicionalmente, a partir de la revisión del estado del arte efectuada, se incorporan dos recomendaciones a tener en consideración por parte de las autoridades:

- Se propone mantener de manera regular la realización de procedimientos de limpieza y desinfección en el transporte público, junto a la sugerencia de continuar utilizando mascarillas faciales en su interior. Lo anterior acompañado de una constante revisión y ajuste de las frecuencias programadas y capacidades de transporte del sistema, cuya definición favorezca el distanciamiento social y la disminución del hacinamiento al interior de los vehículos. Esto podría reducir el miedo y la percepción de riesgo que aún sienten algunas personas hacia el transporte público.

- Por último, se sugiere implementar medidas que desalienten el uso del automóvil, como restringir inversiones enfocadas en priorizar al transporte privado (autopistas urbanas), o bien, evaluar la incorporación de desincentivos económicos a los usuarios del auto (tarificación por ingreso a zonas congestionadas, aumento del valor de estacionamientos). Estas medidas se complementan con mejoras al transporte público, como la construcción de más vías de uso exclusivo para buses.

6.3. Limitaciones del trabajo y líneas futuras de investigación

Los resultados obtenidos en la presente investigación dependen en gran medida de la riqueza de los datos utilizados y del tratamiento dado. En primer lugar, como variable explicada se consideró únicamente un indicador que mide como cambia el número de usuarios del transporte público con el transcurso de la pandemia por COVID-19. En la literatura se plantean otras medidas de movilidad que podría ser de interés estudiar en un futuro y con ellas, reestimar los modelos de regresión multivariada para comparar las conclusiones obtenidas. Algunos de los indicadores de movilidad que se proponen construir como nuevas variables dependientes son:

- i) La variación de la distancia recorrida.
- ii) El cambio en el número de viajes diarios por persona.
- iii) La variación en el número de días en que el pasajero viaja.
- iv) El cambio en la frecuencia y periodicidad con que se visitan ciertos lugares.

Para obtener la variable explicada se contrastó la demanda en el transporte público durante la crisis sanitaria con una situación de referencia, en este caso una semana de marzo 2020 inmediatamente anterior al inicio de la pandemia. Se propone para una futura investigación reconstruir el indicador considerando como situación base los datos de una semana representativa del mismo mes que el corte temporal en análisis, pero de años anteriores (2017 o 2018 por ejemplo).

Independiente de la variable explicada que se utilice, es importante recordar que la data extraída es anónima. Dado que se requiere estimar la zona de residencia de los usuarios para imputarles características socioeconómicas, demográficas, entre otras, se consideró que cada persona es representada por el ID de la tarjeta inteligente. Luego, se infirió la localización de su hogar aplicando la metodología descrita en la literatura. No obstante, teniendo en cuenta la riqueza de las bases de datos disponibles, se propone refinar la estimación a un nivel micro, al menos para los usuarios recurrentes, analizando el comportamiento de la frecuencia de uso de paradas y periodicidad con que viajan desde un mismo origen en las mañanas.

Es importante recalcar que los resultados expuestos ignoran el efecto de la evasión al pago de la tarifa, lo cual genera sesgos en la estimación de la cantidad de usuarios, ya que las bases de datos de transacciones en transporte público utilizadas quedan incompletas. Esto limita principalmente a los cortes temporales que representan el inicio de la pandemia por COVID-19, cuando por medidas de prevención de contagios y para evitar aglomeraciones se permitió a los

pasajeros abordar los buses sin validar su tarjeta. Por lo tanto, se sugiere aplicar nuevas metodologías que permitan incorporar a la evasión en análisis futuros y verificar el impacto que pueda causar en las conclusiones planteadas.

Respecto a las variables explicativas utilizadas, cabe mencionar que algunas de ellas fueron construidas a partir de data antigua. Por ende, su efecto en el área en cuestión puede no ser del todo representativo, como es el caso de la tasa de motorización, la cual se encuentra desactualizada. Se sugiere indagar en más fuentes de información, con la finalidad de incorporar una variable asociada a la posesión de autos por hogar capaz de reflejar el incremento observado durante la crisis sanitaria.

Paralelamente, en algunos casos se usaron factores con un mayor nivel de agregación que el considerado en la modelación, por lo que se obtuvo poca variabilidad entre observaciones. Este es el caso de la variable días corridos en cuarentena. Se recomienda, por lo tanto, buscar datos asociados específicamente a la etapa de confinamiento en la ciudad, con desagregación por distrito censal, para representar el posible impacto involucrado.

A su vez, existe información que no fue posible obtener con las bases de datos disponibles para el nivel de desagregación requerido y que podrían ser importantes para determinar los factores que inciden en la disminución de la cantidad de usuarios del transporte público. Éstas tienen relación con la posibilidad de realizar teletrabajo y comprar de forma online. En caso de no disponer de una data que permita recrear estos factores, se propone generar un listado de rubros que no requerirían presencialidad y estimar la proporción de personas con ocupaciones no esenciales, utilizando de los resultados entregados por el último CENSO.

Otras variables que se postulan para trabajos futuros con el objetivo de complementar el análisis sobre recuperación de la movilidad son: indicador de las tasas de vacunación, índice que mida el miedo a utilizar el transporte público, proporción de personas con estudios en educación superior completos y kilómetros lineales de ciclovías dentro de cada área.

Finalmente, la metodología considerada y los datos usados no permiten evidenciar cambios en la estructura de actividades de los pasajeros del transporte público producto de la pandemia. Para ello, se requeriría inferir el propósito de viaje y reconstruir el diario de actividades de los usuarios en cada corte temporal estudiado, lo cual muestra dificultades en aquellos casos donde no es posible estimar la bajada. Luego, la secuencia de viajes y actividades diarias puede quedar incompleta y no ser representativa. Sin perjuicio de lo anterior, se propone abordar esta línea de investigación y complementar los resultados presentados.

Bibliografía

- Abdullah, M., Días, C., Muley, D. & Shanin, M. (2020). Exploring the impacts of COVID-19 on travel behavior and mode preferences. *Transportation Research Interdisciplinary Perspectives*. 8, 100255. <https://doi.org/10.1016/j.trip.2020.100255>
- Agard, B., Morency, C. & Trépanier, M. (2006). Mining public transport user behavior from smart card data. *IFAC Proceedings Volumes*. 39 (3), 399-404. <https://doi.org/10.3182/20060517-3-FR-2903.00211>
- Ahangari, S., Chavis, C. & Jeihani, M. (2020). Public transit ridership analysis during the COVID-19 Pandemic. *MedRxiv*. Publicación anticipada en línea. <https://doi.org/10.1101/2020.10.25.20219105>
- Alsger, A., Tavassoli, A., Mesbah, M., Ferreira, L. & Hickman, M. (2018). Public transport trip purpose inference using smart card fare data. *Transportation Research Part C: Emerging Technologies*. 87, 123-137. <https://doi.org/10.1016/j.trc.2017.12.016>
- Amaya, M. (2013). Análisis de patrones de viaje utilizando datos masivos de transporte público. [Tesis para optar al grado de Magister en Ciencias de la Ingeniería, mención Transporte]. Universidad de Chile.
- Amaya, M., Cruzat, R. & Munizaga, M.A. (2018). Estimating the residence zone of frequent public transport users to make travel pattern and time use analysis. *Journal of Transport Geography*. 66, 330–339. <https://doi.org/10.1016/j.jtrangeo.2017.10.017>
- ANAC. (2020). Conferencia de prensa ANAC 2021: Resultados año 2020 y proyecciones 2021. <https://www.anac.cl/wp-content/uploads/2021/02/CONFERENCIA-DE-PRENSA-ANAC-2021-VF.pdf>
- ANAC. (2021). Conferencia de prensa ANAC 2021: Resultados año 2021 y proyecciones 2022. <https://www.anac.cl/wp-content/uploads/2022/01/Conferencia-de-prensa-resultados-2021.pdf>
- Astroza, S., Tirachini, A., Hurtubia, R., Carrasco, J.A., Guevara, A., Munizaga, M.A., Figueroa, M. & Torres, V. (2020). Mobility changes, teleworking, and remote communication during the COVID-19 pandemic in Chile. *Findings*. <https://doi.org/10.32866/001c.13489>

- Barry, J.J., Newhouser, R., Rahbee, A. & Sayeda, S. (2002). Origin and destination estimation in New York City with automated fare system data. *Transportation Research Record: Journal of the Transportation Research Board*. 1817, 183–187. <https://doi.org/10.3141/1817-24>
- Basnak, P., Giesen, R. & Muñoz, J.C. (2022). Estimation of crowding factors for public transport during the covid-19 pandemic in Santiago, Chile. *Transportation Research Part A: Policy and Practice*. 159, 140–156. <https://doi.org/10.1016/j.tra.2022.03.011>
- Bagchi, M. & White, P.R. (2005). The potencial of public transport smart card data. *Transport Policy*. 12 (5), 464-474. <http://dx.doi.org/10.1016/j.tranpol.2005.06.008>
- Bohnensteffen, S., Mühlhan, J. & Saidani, Y. (2021). Mobilität während der Corona-Pandemie. *WISTA – Wirtschaft und Statistik*. 73 (3), 89-105. <http://hdl.handle.net/10419/235268>
- Borrego, J.A. (2018). Modelos de regresión para datos espaciales. [Trabajo para optar al grado en Matemáticas]. Universidad de Sevilla.
- Brough, R., Freedman, M. & Phillips, D.C. (2021). Understanding socioeconomic disparities in travel behavior during the COVID-19 pandemic. *Journal of Regional Science*. 61 (4), 753-774. <https://doi.org/10.1111/jors.12527>
- Bucsky, P. (2020). Modal share changes due to COVID-19: the case of Budapest. *Transportation Research Interdisciplinary Perspectives*. 8, 100141. <https://doi.org/10.1016/j.trip.2020.100141>
- Chakirov, A. & Erath, A. (2012). Activity identification and primary location modelling based on smart card payment data for public transport. 13th International Conference on Travel Behaviour Research, Toronto, Canadá.
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0: Step-by-step data mining guide*.
- Chriqui, C. & Robillard, P. (1975). Common bus line. *Transportation Science*. 9, 115–121. <https://doi.org/10.1287/TRSC.9.2.115>
- Chu, K. K. A. & Chapleau, R. (2008). Enriching archived smart card transaction data for transit demand modeling. *Transportation Research Record: Journal of the Transportation Research Board*. 2063 (1), 63–72. <https://doi.org/10.3141/2063-08>
- De Haas, M., Faber, R. & Hamersma, M. (2020). How COVID-19 and the Dutch ‘intelligent lockdown’ change activities, work and travel behaviour: Evidence from longitudinal data in The Netherlands. *Transportation Research Interdisciplinary Perspectives*. 6, 100150. <https://doi.org/10.1016/j.trip.2020.100150>

- De Vos, J. (2020). The effect of COVID-19 and subsequent social distancing on travel behavior. *Transportation Research Interdisciplinary Perspectives*. 5, 100121. <https://doi.org/10.1016/j.trip.2020.100121>
- Devillaine, F., Munizaga, M.A. & Trépanier, M. (2012). Detection of activities of public transport users by analyzing smart card data. *Transportation Research Record: Journal of the Transportation Research Board*. 2276 (1), 48-55. <https://doi.org/10.3141/2276-06>
- Directorio de Transporte Público Metropolitano. (2021). Programas de Operación 2021. <https://www.dtpm.cl/index.php/noticias/plan-operacional-historico>
- Directorio de Transporte Público Metropolitano. (2021). Informe de gestión 2021. https://www.dtpm.cl/descargas/memoria/Informe_Gestion_2021.pdf
- El Mahrsi, M.K., Côme, E., Oukhellou, L. & Verleysen, M. (2017). Clustering smart card data for urban mobility analysis. *IEEE Transactions on Intelligent Transportation Systems*. 18 (3), 712-728. 10.1109/TITS.2016.2600515
- Espinoza, C. (2017). Caracterización y reconocimiento de usuarios a través de la observación de su movilidad en transporte público. [Tesis para optar al grado de Magíster en Ciencias mención Computación]. Universidad de Chile.
- Gkiotsalitis, K. & Cats, O. (2021). Public transport planning adaption under the COVID-19 pandemic crisis: literature review of research needs and directions. *Transport Reviews*. 41 (3), 374-392. <https://doi.org/10.1080/01441647.2020.1857886>
- Gramsch, B., Guevara, C.A., Munizaga, M.A., Schwartz, D. & Tirachini, A. (2022). The effect of dynamic lockdowns on public transport demand in times of COVID-19: Evidence from smartcard data. *Transport Policy*. 126, 136-150. <https://doi.org/10.1016/j.tranpol.2022.06.012>
- Gschwender, A., Munizaga, M.A. & Simonetti, C. (2016). Using smart card and GPS data for policy and planning: the case of Transantiago. *Research in Transportation Economics*. 59, 242-249. <https://doi.org/10.1016/j.retrec.2016.05.004>
- Guevara, A. (2022). Demanda de Transporte [Apunte de los cursos CI-5308 / CI3242 Demanda de Transporte / Análisis de Datos para Ingeniería]. Universidad de Chile, Santiago.
- Hastie, T., Tibshirani, R. & Friedman, J. (2017). The elements of statistical learning: data mining, inference, and prediction (2^a ed.). Springer Series in Statistics.

- Hausman, J.A. (1978). Specification Test in Econometrics. *Econometrica*.46(6), 1251-1271. <https://doi.org/10.2307/1913827>
- Hu, S. & Chen, P. (2021). Who left riding transit? Examining socioeconomic disparities in the impact of COVID-19 on ridership. *Transportation Research Part D: Transport and Environment*. 90, 102654. <https://doi.org/10.1016/j.trd.2020.102654>
- Instituto Nacional de Estadística. (2017). Censo de Población y Vivienda. <https://www.ine.cl/estadisticas/sociales/censos-de-poblacion-y-vivienda/poblacion-y-vivienda>
- Instituto Nacional de Estadística. (2022). Remuneraciones y Costos de Mano de Obra. <https://www.ine.cl/estadisticas/sociales/mercado-laboral/remuneraciones-y-costos-laborales>
- ISCI & Entel OCEAN. (2022). Visor de Movilidad, Evolución de la Movilidad por Comunas. <https://covidanalytics.isci.cl/movilidad/visor-movilidad/>
- Islind, A.S., Óskarsdóttir, M. & Steingrímssdóttir, H. (2020). Changes in mobility patterns in Europe during the COVID-19 pandemic: Novel insights using open source data. ArXiv. Publicación anticipada en línea. <https://doi.org/10.48550/arXiv.2008.10505>
- James, G., Witten, D., Hastie, T. & Tibshirani, R. (2021). An introduction to statistical learning with applications in R (2^a ed.). Springer Series in Statistics.
- Kellermann, R., Sivizaca, D., Röbler, D. & Kliewer, N. (2022). Mobility in pandemic times: Exploring changes and long-term effects of COVID-19 on urban mobility behavior. *Transportation Research Interdisciplinary Perspectives*. 15, 100668. <https://doi.org/10.1016/j.trip.2022.100668>
- Lee, S. G. & Hickman, M. (2014). Trip purpose inference using automated fare collection data. *Public Transport*. 6, 1-20. <https://doi.org/10.1007/s12469-013-0077-5>
- LeSage, J. & Kelley Pace, R. (2009). Introduction to Spatial Econometrics. CRC Press Taylor & Francis Group.
- Li, G., Yu, L., Wu, W., Ng, W. S. & Goh, S. T. (2015). Predicting home and work locations using public transport smart card data by spectral analysis. 2015 IEEE 18th International Conference on Intelligent Transportation Systems. <http://dx.doi.org/10.1109/ITSC.2015.445>
- Liu, L., Miller, H.J. & Scheff, J. (2020). The impacts of COVID-19 pandemic on public transit demand in the United States. *PLoS ONE*. 15(11). <https://doi.org/10.1371/journal.pone.0242476>

- Ma, X., Wu, Y., Wang, Y., Chen, F. & Liu, J. (2013). Mining smart card data for transit riders' travel patterns. *Transportation Research Part C: Emerging Technologies*. 36, 1-12. <https://doi.org/10.1016/j.trc.2013.07.010>
- Mella, B. (2013). Metro como oportunidad de intervención en la ciudad. Exploración analítica y proyectual en Estación Carmelitas. [Tesis para optar al título de Arquitecto y grado de Magíster en Desarrollo Urbano]. Universidad Católica.
- Ministerio del Interior y Seguridad Pública. (2021). Comunas de la Provincia. <http://www.delegacionsantiago.gov.cl/comunas-de-la-provincia/>
- Ministerio de Salud. (2020). Paso a paso nos cuidamos. <https://www.minsal.cl/wp-content/uploads/2020/07/ConocePlanPasoPaso.pdf>
- Ministerio de Salud. (2022). COVID-19 en Chile: Pandemia 2020-2022. https://www.minsal.cl/wp-content/uploads/2022/03/2022.03.03_LIBRO-COVID-19-EN-CHILE-1-1.pdf
- Ministerio de Transporte y Telecomunicaciones. (2012). Encuesta Origen Destino Santiago 2012. <http://www.sectra.gob.cl/biblioteca/detalle1.asp?mfn=3253>
- Ministerio de Transporte y Telecomunicaciones. (19 de Mayo de 2020). Prensa. Transporte público capitalino registra la menor cantidad de validaciones en un día hábil desde que se inició la pandemia. <https://www.mtt.gob.cl/archivos/25182>
- Ministerio de Transporte y Telecomunicaciones. (9 de Abril de 2021). Prensa. Entregamos Balance de ciclovías a nivel nacional e informa incremento de 27,9% en los últimos tres años. <https://www.mtt.gob.cl/archivos/28458>
- Ministerio de Transporte y Telecomunicaciones & Ministerio de Bienes Nacionales. (2021). Visor territorial de ciclovías. <https://ciclovias.visorterritorial.cl/>
- Molloy, J., Schatzmann, T., Schoeman, B., Tchervenkov, C., Hintermann, B. & Axhausen, K. W. (2021). Observed impacts of the Covid-19 first wave on travel behaviour in Switzerland based on a large GPS panel. *Transport Policy*. 104, 43-51. <https://doi.org/10.1016/j.tranpol.2021.01.009>
- Monterde-i-Bort, H., Sucha, M., Risser, R. & Kochetova, T. (2022). Mobility patterns and mode choice preferences during the Covid-19 situation. *Sustainability*. 14 (2), 768. <https://doi.org/10.3390/su14020768>

- Morency, C., Trépanier, M. & Agard, B. (2007). Measuring transit use variability with smart-card data. *Transport Policy*. 14 (3), 193–203. <https://doi.org/10.1016/j.tranpol.2007.01.001>
- Munizaga, M.A. & Palma, C. (2012). Estimation of a disaggregate multimodal public transport origin-destination matrix from passive smartcard data from Santiago, Chile. *Transportation Research Part C: Emerging Technologies*. 24, 9–18. <https://doi.org/10.1016/j.trc.2012.01.007>
- Munizaga, M.A., Beltrán, P., Cortés, C., Gschwender, A., Ibarra, R., Palma, C., Ortega, M. & Zuñiga, M. (2012). Obtención de información valiosa a partir de datos de Transantiago. *Ingeniería de Transporte*. 16 (2), 34-47.
- Munizaga, M.A., Devillaine, F., Navarrete, C. & Silva, D. (2014). Validating travel behavior estimated from smartcard data. *Transportation Research Part C: Emerging Technologies*. 44, 70-79. <https://doi.org/10.1016/j.trc.2014.03.008>
- Munizaga, M.A., Gschwender, A. & Gallegos, N. (2020). Fare evasion correction for smartcard-based origin-destination matrices. *Transportation Research Part A: Policy and Practice*. 141, 307–322. <https://doi.org/10.1016/j.tra.2020.09.008>
- Muñoz, V., Thomas, A., Navarrete, C. & Contreras, R. (2015). Encuesta origen-destino de Santiago 2012: Resultados y validaciones. *Ingeniería de Transporte*. 19 (1), 21-36.
- Murillo, C. & González, B. (2000). Validación del modelo de regresión: contrastes de especificación. En *Manual de Econometría*.
- Olguín, J., Jara-Díaz, S. & Munizaga, M.A. (2009). Análisis de patrones de actividades a partir de la EOD 2001. *Ingeniería de Transporte*. 13 (4), 31-38.
- Pardo, C.F., Zapata-Bedoya, S., Ramírez-Varela, A., Ramírez-Corrales, D., Espinosa-Oviedo, J.J, Hidalgo, D., Rojas, N., González-Uribe, C., García, J.D. & Cucunubá, Z.M. (2021). COVID-19 and public transport: an overview and recommendations applicable to Latin America. *Infectio*. 25 (3), 182. <https://doi.org/10.22354/in.v25i3.944>.
- Pelletier, M., Trépanier, M. & Morency, C. (2011). Smart card data use in public transit: A literatura review. *Transportation Research Part C: Emerging Technologies*. 19 (4), 557-568. <https://doi.org/10.1016/j.trc.2010.12.003>
- Qi, Y., Liu, J., Tao, T. & Zhao, Q. (2021). Impacts of COVID-19 on public transit ridership. *International Journal of Transportation Science and Technology*. Publicación anticipada en línea. <https://doi.org/10.1016/j.ijtst.2021.11.003>
- Tabachnick, B.G. & Fidell, I.S. (2012). *Using multivariate statistics* (7^a ed.). Pearson.

- Tao, S., Rohde, D. & Corcoran, J. (2014). Examining the spatial–temporal dynamics of bus passenger travel behaviour using smart card data and the flow-comap. *Journal of Transport Geography*. 41, 21–36. <https://doi.org/10.1016/j.jtrangeo.2014.08.006>
- Tirachini, A. & Cats, O. (2020). COVID-19 and public transportation: current assessment, prospects, and research needs. *Journal of Public Transportation*. 22 (1). <https://doi.org/10.5038/2375-0901.22.1.1>
- Trépanier, M., Tranchant, N. & Chapleau, R. (2007). Individual trip destination estimation in a transit smart card automated fare collection system. *Journal of Intelligent Transportation Systems*. 11 (1), 1–14. <https://doi.org/10.1080/15472450601122256>
- Utsunomiya, M., Attanucci, J. & Wilson, N. (2006). Potential uses of transit smart card registration and transaction data to improve transit planning. *Transportation Research Record: Journal of the Transportation Research Board*. 1971 (1), 119–126. <https://doi.org/10.1177/0361198106197100114>
- Vela, F. (2010). Normalidad de los errores. Universidad Autónoma Metropolitana. México, D.F.
- Wang, J., Huang, J., Yang, H. & Levinson, D. (2022). Resilience and recovery of public transport use during COVID-19. *Npj Urban Sustainability* 2. 18. <https://doi.org/10.1038/s42949-022-00061-1>
- Wilbur, M., Ayman, A., Ouyang, A., Poon, V., Kabir, R., Vadali, A., Pugliese, P., Freudberg, D., Laszka, A. & Dubey, A. (2020). Impact of covid-19 on public transit accessibility and ridership. *ArXiv*. Publicación anticipada en línea. <https://doi.org/10.48550/arXiv.2008.02413>.
- Wooldridge, J. M. (2009). *Introductory Econometrics: A Modern Approach* (4^a ed.). South-Western Cengage Learning.
- Zhao, J., Rahbee, A. & Wilson, N. (2007). Estimating a rail passenger trip origin-destination matrix using automatic data collection systems. *Computer-Aided Civil and Infrastructure Engineering*. 22 (5), 376–387. <https://doi.org/10.1111/j.1467-8667.2007.00494.x>