



Universidad del Desarrollo
Facultad de Ingeniería

PROYECTO

Impacto de uso de suelo en la movilidad de la Región Metropolitana, en tiempo de
pandemia.

POR: SERGIO ARANCIBIA P.

PROFESOR: DRA. DANIELA OPITZ

Enero 2021
SANTIAGO

TABLA DE CONTENIDO

1	ABSTRACT	1
2	INTRODUCCIÓN	2
3	REVISIÓN BIBLIOGRÁFICA	3
3.1	COVID-19 EN CHILE	3
3.2	ESTUDIOS DE MOVILIDAD CON DATOS DE TELEFONÍA MÓVIL COMO APOYO PARA EL CONTROL DE LA PANDEMIA	4
3.2.1	<i>Evaluación de medidas sanitarias.....</i>	4
3.2.2	<i>Causas de las variaciones de las medidas de movilidad.....</i>	5
4	HIPÓTESIS	6
5	OBJETIVOS	6
5.1	OBJETIVO GENERAL.....	6
5.2	OBJETIVOS ESPECÍFICOS	6
6	MODELO DE REGRESIÓN PONDERADA GEOGRÁFICAMENTE (GWR).....	7
6.1	FUNCIÓN DE REGRESIÓN PONDERADA GEOGRÁFICAMENTE (GWR)	8
6.2	CÁLCULO DE MATRIZ DE PESOS GWR	9
6.3	ESTIMACIÓN DE MODELOS ESPACIALES.....	10
7	DESCRIPCIÓN DE DATOS	13
7.1	DESCRIPCIÓN DE LOS DATOS	¡ERROR! MARCADOR NO DEFINIDO.
7.1.1	<i>Open Street map.....</i>	13
7.1.2	<i>Índice de movilidad.....</i>	17
8	METODOLOGÍA	20
8.1	SELECCIÓN DE VARIABLES INDEPENDIENTES.....	20
8.2	ASIGNACIÓN DE PESOS	22
8.3	ESTIMACIÓN DE PARÁMETROS $\hat{\beta}_i$ LOCALES.....	22
8.4	FECHAS DESTACADAS	22
9	RESULTADOS.....	23
9.1	RESULTADOS DE R^2	23
9.1.1	<i>Resultados de R^2 para índices de movilidad externos.....</i>	23

9.1.2	<i>Resultados de R^2 para índices de movilidad internos.....</i>	24
9.2	RESULTADOS DE LOS COEFICIENTES LOCALES	26
9.2.1	<i>Resultados de los coeficientes locales para los índices de movilidad externos.....</i>	26
9.2.2	<i>Resultados de los coeficientes locales para los índices de movilidad interna.....</i>	33
10	CONCLUSIONES	41
11	TRABAJO FUTURO	42
12	BIBLIOGRAFÍA.....	43

1 Abstract

Actualmente el mundo enfrenta una pandemia de coronavirus SARS-COV-2, causante de la enfermedad COVID-19 la que ha causado 1.320.148 muertos hasta al 17 de noviembre del 2020 y superando los cincuenta y cuatro millones de infectados (W.H.O., 2020). En Chile, para controlar la propagación del virus, el gobierno ha implementado distintas medidas tales como la suspensión de clases y el decreto de cuarentenas a nivel de comuna y de región, basándose en distintos criterios, incluyendo indicadores de movilidad de las personas a nivel de comuna. En este proyecto se presenta un análisis de la relación de la movilidad en la población de la Región Metropolitana, obtenida a través de registros telefónicos móviles asociados a antenas telefónicas de la empresa Telefónica S.A y los distintos tipos de establecimientos pertenecientes a las comunas de la Región Metropolitana obtenidos de la plataforma Open Street Map (OSM) y clasificadas según las categorías: educación, retail, trabajo y vida nocturna, provistas por dicha plataforma. Esta relación se obtuvo a través de regresiones geoespaciales con datos para a tres hitos referentes al manejo de la pandemia en Chile: suspensión de clases y cuarentena parcial y total en la Región Metropolitana. Nuestro resultado más significativo señala que luego que se decretara cuarentena parcial y total, la disponibilidad de establecimientos en las comunas en las que se implementaron restricciones no impacta significativamente en la movilidad externa de estas, lo que podría explicarse por la gran cantidad y diversidad de establecimientos de todo tipo que poseen estas comunas, en contraste al que tienen las comunas periféricas.

Las comunas q poseen establecimientos no requieren salir

Palabras Clave

movilidad, datos de telefonía celular, coronavirus, COVID-19

2 Introducción

Actualmente el mundo enfrenta una pandemia de coronavirus (COVID-19) causada por el virus SARS-COV-2, originado en el país de China en la ciudad de Wuhan y cuyos primeros casos fueron reportados por la Organización mundial de la salud (OMS) entre los días 12 y 29 de diciembre (OMS[1], 2019). Esta enfermedad causa infecciones respiratorias que pueden causar desde un resfrió común hasta complicaciones más graves como el síndrome respiratorio agudo severo (SRAS) en la población (OMS[2], 2019), lo que la hace muy letal y la vuelve una amenaza para la población mundial tanto en nivel rural como urbano. Debido a la facilidad con que una persona puede contagiar a otra y al poco conocimiento que se tenía del virus, este se propagó rápidamente por el mundo, llegando a Chile el día 3 de marzo.

Desde hace años que el mundo no se veía enfrentado a una pandemia de magnitud como la actual. Lo más parecido que ha enfrentado el mundo en los últimos veinte años, ha sido el virus de inmunodeficiencia adquirida (VIH) causante de la enfermedad del SIDA, cuyos primeros casos se conocieron el año 1981 (Sepkowitz, 2001).

La enfermedad de coronavirus COVID-19, ha causado 1.320.148 de muertes en todo el mundo al día 17 de noviembre (W.H.O., 2020) y en ausencia de una vacuna o tratamiento efectivo, reducir su propagación para controlar el número de contagios es crítico. Esta reducción requiere de la implementación de distintas medidas, principalmente enfocadas a restringir el contacto social y la movilidad de las personas, y la coordinación de actores sociales, culturales, políticos, económicos y científicos. En este contexto, el desarrollo de estudios y modelos sobre la propagación del virus que ayuden a tomar decisiones para controlar la pandemia del COVID-19 y para entender el impacto de estas, es de suma relevancia.

Dada la importancia de restringir el contacto social y controlar la movilidad de las personas, distintos grupos de investigación e instituciones han elaborado distintas mediciones de movilidad utilizando distintas fuentes de datos tales como datos referentes al uso del transporte público, datos obtenidos a través de la georreferenciación de la personas o registros de telefonía móvil. En China, país en el cual se registraron los primeros casos declarados casos por ejemplo, se tomaron rápidamente drásticas medidas de control de la movilidad de la población, en base a los datos de

viajes en tiempo real provenientes de la empresa de servicios de internet Baidu, lo que, junto a otras estrategias, permitió mitigar propagación del virus (Kraemer, 2020). Chile actualmente cuenta con un índice que permite medir la movilidad utilizando registros telefónicos (Pappalardo, Cornacchia, Navarro, Bravo, & Ferres, 2020), el cual es utilizado por el gobierno del país, para tomar decisiones con respecto a las restricciones de movilidad.

En este trabajo utilizamos las categorías de Open Street Map (OpenStreetMap contributors, (2015)) y la vinculamos con el índice de movilidad calculado por el Instituto de Data Science y para explicar la movilidad de personas en las distintas comunas de la Región Metropolitana, a través de la implementación de una regresión geoespacial.

A continuación, en la sección 3 presentamos una breve revisión bibliográfica de algunos estudios de movilidad vinculados al manejo de la pandemia, en la sección 4 y 5 detallamos la hipótesis y los objetivos de este trabajo, mientras que en la sección 6 presentamos un marco teórico referente al manejo de datos geoespaciales. Finalmente, en las secciones 7, 8 y 9 presentamos una descripción detallada de los datos utilizados, la metodología y los principales resultados.

3 Revisión bibliográfica

3.1 COVID-19 en Chile

Los primeros casos de COVID-19 en Chile se detectaron el día 3 de marzo. El día de mayor número de contagios fue el día 14-06-2020, llegando a 6938 casos (MINSAL, Gobierno de Chile coronavirus, 2020), luego posterior a esta cifra comenzó a disminuir el número de contagios nuevos por día, llegando aproximadamente entre 2000 y 1500 nuevos casos confirmados por día. El número de exámenes PCR realizados diariamente ha aumentado, llegando a un máximo de 42.701 el día 08-11-2020 (MINSAL, Gobierno de Chile coronavirus, 2020).

A la fecha de escritura de este proyecto, las muertes por COVID-19 en Chile han alcanzado la cifra de 15.278 defunciones acumuladas (MINSAL, Sistema de Notificación EPIVIGILA. Depto. de Epidemiología, DIPLAS, 2020)

3.2 Estudios de movilidad con datos de telefonía móvil como apoyo para el control de la pandemia

Debido a que el virus que causa la enfermedad COVID-19 se propaga principalmente por proximidad de persona a persona, entender la movilidad de población es relevante, porque principalmente permite ayudar a las autoridades a tomar decisiones entorno a las medidas de distanciamiento social y restricciones de movilidad y monitorear el cumplimiento de estas.

La movilidad puede ser medida utilizando distintas fuentes de datos, tales como datos referentes al sistema de transporte público, registros de pagos en transacciones de crédito o datos de telefonía móvil, entre otros.

En esta sección presentamos algunos de los estudios de movilidad más relevantes en el contexto del control de la pandemia de COVID-19, y que utilizan datos de telefonía móvil, esto es: registros detallados de telefonía móvil (CDR), los registros extendidos de telefonía móvil (XDR), datos de uso de aplicaciones o datos de posicionamiento global (GPS) de teléfonos celulares, entre otros.

Estos trabajos son agrupados en dos subsecciones, en donde la primera corresponde a trabajos relacionados a la evaluación de medidas sanitarias determinadas por las autoridades y la segunda a trabajos que explican las diferencias en las medidas de movilidad a nivel espacial.

3.2.1 Evaluación de medidas sanitarias

Una revisión detallada de los estudios de movilidad que utilizan estos datos de telefonía móvil hasta abril del año 2020, y una guía de como estos datos pueden ayudar a las autoridades de los gobiernos y de salud pública para tomar mejores decisiones para controlar la pandemia, puede ser encontrada en el trabajo de Oliver et al 2020.

De esta revisión, destacamos dos trabajos, el de Kraemer, 2020 y el Bengtsson, et al, 2015.

(Kraemer, 2020) constituye uno de los primeros trabajos que se desarrollaron para evaluar el efecto de una medida de restricción utilizando datos de teléfonos móviles. En este estudio, se utilizaron datos de movilidad -calculados a partir de conexiones GPS, conexiones a antenas y otras fuentes, de las personas provistos por la empresa Baidu y datos de personas contagiadas, para estudiar el

efecto del cierre de la ciudad de la ciudad de Wuhu, China, en la propagación del virus. Los autores de este estudio concluyeron que en la etapa inicial de la pandemia, la distribución espacial de los contagios se explica bien por los datos de movilidad.

El trabajo de Bengtsson, et al, 2015 por otro lado utiliza los datos de los operadores móviles para predecir la evolución espacial temprana de la epidemia del colera en Haití del año 2010, mediante dos modelos matemáticos. Como resultado obtuvieron que el modelo basado en teléfono móvil tuvo un mejor rendimiento que los modelos de gravedad optimizados retroactivamente. Finalmente, los datos del operador móvil son una fuente de datos muy prometedora para mejorar los esfuerzos de preparación y respuestas durante los brotes de colera.

De los trabajos posteriores al mes de abril del año 2020, destacamos los trabajos de Hadjidemetriou et al 2020, quienes utilizando datos públicos de movilidad para UK, provenientes de la empresa Apple, calculados a partir de conexiones GPS, concluyen que la reducción de la movilidad disminuye significativamente el número de muertes por COVID-19.

3.2.2 Causas de las variaciones de las medidas de movilidad

Algunos trabajos de movilidad basados de datos de telefonía móvil, han revelado diferencias en la movilidad de las personas en el contexto de la pandemia, que se explican por distintas razones.

Un estudio realizado por Weill, Stigler, Deschenes, & Springborn, 2020 con datos de movilidad de Estados Unidos, provistos por la empresa Google, revela que las áreas con mayores ingresos, disminuyeron su índice de movilidad significativamente más que las áreas con menores ingresos.

En la misma línea, un estudio elaborado por Gozzi, et al, 2020 utilizando registros detallados extendidos (XDR) de telefonía móvil de la Región Metropolitana, provenientes de la empresa Telefónica Movistar, reporta una fuerte correlación entre las variaciones de movilidad y los indicadores económicos y sociales.

4 Hipótesis

- Los distintos patrones de movilidad registrados en las comunas de la región metropolitana, durante las restricciones de movilidad y cuarentena decretadas durante el 2020, pueden ser explicados por las distintas distribuciones de establecimientos en cada una de ellas.

5 Objetivos

5.1 Objetivo general

- Entender la relación entre el índice de movilidad y los distintos tipos de establecimientos (salud, educación, retail, etc) para las distintas comunas de la Región Metropolitana.

5.2 Objetivos específicos

- Extraer, depurar y clasificar la información según los distintos tipos de establecimientos para cada comuna.
- Estudiar y aplicar alguna metodología para cuantificar la relación entre el índice de movilidad y la presencia de distintos tipos de establecimiento para cada comuna.

6 Modelo de regresión ponderada geográficamente (GWR)

La regresión ponderada geográficamente, fue desarrollada por Oshan, Li, Kang, & Wolf, 2019. Estos autores crean una metodología para un caso particular de un modelo de regresión espacial, tal como la regresión local. Este modelo capta la heterogeneidad espacial del proceso (es decir la variación espacial por contexto espacial) a través de una operacionalización de la primera ley de Tobler “Todo está relacionado con todo, pero las cosas más cercanas están más relacionadas a las lejanas” (Waldo, 1970).

Este modelo se basa en un conjunto de modelos lineales locales, se ajustan en cualquier número de lugares “Tomando prestado” datos cercanos. El resultado es una superficie de estimaciones de parámetros específicos de la ubicación i para cada relación en el modelo, que también pueden variar espacialmente como un único parámetro de ancho de banda, que proporciona una intuición sobre la escala geográfica de los procesos. Además, el GWR normalmente proporciona un mayor ajuste del modelo y una reducción de la autocorrelación espacial residual comparada con una regresión global tradicional que asume que las relaciones son constantes en el espacio.

Una reciente extensión del GWR permite que cada relación del modelo varíe en una escala espacial única, esta se conoce como regresión ponderada geográficamente multiescalar (Fotheringham, Yang, & Kang, 2017) en adelante como MGWR. El MGWR es mucho menos restrictivo en los supuestos que un modelo GWR, ya que la relación entre la respuesta y una covariable se permite entre variación local, regional o que no varíe en absoluto. Eliminando la restricción de que todas las relaciones varíen en la misma escala espacial puede a minimizar el sobre ajuste, reducir el sesgo en las estimaciones de los parámetros y reducir colinealidad debido a las transformaciones funcionales similares. Por lo tanto, el MGWR ha sido un sugerido como la especificación del modelo local por defecto cuando se utiliza el GWR para investigar un proceso espacial heterogéneos y de escala.

Para entender el método de cálculo del MGWR primero se presentará el método GWR,

6.1 Función de regresión ponderada geográficamente (GWR)

El GWR ajusta un modelo de regresión en cada lugar por medio de un esquema de préstamos de datos, que pondera las observaciones distintas de cada lugar sirviendo como punto de regresión. Un modelo GWR se puede especificar como:

$$y_i = \beta_{i0} + \sum_{k=1}^p \beta_{ik} x_{ik} + \varepsilon_i, \quad i = 1, \dots, n$$

En donde (1)

y_i : es la variable dependiente de la ubicación i

β_{i0} : es el coeficiente de intersecciones de la ubicación i

x_{ik} : es la k -ésima variable explicativa en la ubicación i

β_{ik} : es el k -ésimo coeficiente de regresión de la variable explicativa x_{ik} en la ubicación i

ε_i : es el término de error aleatorio asociado a la ubicación i

Normalmente i viene indicado por coordenadas geográficas bidimensionales (u_i, v_i) indicando la ubicación del punto de la regresión, en forma de matriz. El estimador de GWR para las estimaciones de los parámetros locales para cada sitio i viene dado por:

$$\hat{\beta}(i) = [X^t W(i) X]^{-1} X^t W(i) y \quad (2)$$

Donde X es una matriz de $n \times k$ de variables explicativas, $W(i) = \text{diag}[w_1(i), \dots, w_n(i)]$ es una matriz de $n \times n$ de pesos diagonales, que pondera cada observación basada en su distancia a la ubicación i , $\hat{\beta}(i)$ corresponde a un vector de coeficientes de dimensión $k \times 1$ y finalmente y es un vector de $k \times 1$ observaciones de la variable dependiente. Las entradas del modelo son X , y y las coordenadas geográficas (u, v) .

6.2 Cálculo de matriz de pesos GWR

Para calcular la matriz de pesos a utilizar en GWR, se aplica una función de kernel para calcular las distancias entre las observaciones y los puntos de calibración. Este kernel pone más énfasis en las observaciones que están más cerca que las que están más lejos. Las funciones kernel más utilizadas son la gaussiana, exponencial y bi-cuadrada. A continuación, en la tabla N 3 se presenta el cálculo de cada una de ellas respectivamente:

Función	Especificación
Gaussiana	$w_{ij} = \exp\left(-\frac{1}{2}\left(\frac{d_{ij}}{b}\right)^2\right)$
Exponencial	$w_{ij} = \exp\left(-\left(\frac{ d_{ij} }{b}\right)\right)$
Bi-square	$w_{ij} = \begin{cases} (1 - (d_{ij}/b)^2)^2 & \text{si la distancia entre centroide } d_{ij} < d \\ 0 & \text{caso contrario} \end{cases}$

Tabla 3: Funciones para el cálculo de pesos espaciales (Oshan, li, Kang, & Wolf, 2019)

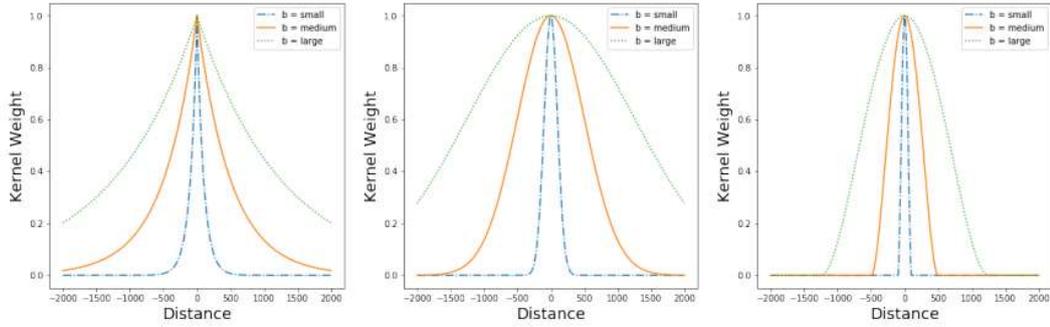


Figura 6: Ancho de banda por función de kernel (Oshan, li, Kang, & Wolf, 2019).

6.3 Estimación de modelos espaciales

La estimación de los modelos de regresión espacial se suele llevar a cabo mediante el método de máxima verosimilitud, en donde la probabilidad de la distribución conjunta de todas las observaciones se maximiza con respecto a una serie de parámetros relevantes. La estimación de máxima verosimilitud tiene propiedades teóricas, como la eficiencia, consistencia y normalidad asintótica, también funciona para muestras con una distribución con pequeñas variaciones cercanas a la normalidad.

Los problemas de estimación asociados a los modelos de regresión espacial son distintos si es de retardo espacial (SAR) o de error espacial. Analizaremos primero el modelo SAR, usaremos como base el modelo Durbin ya que este puede ser escrito como un modelo SAR Dado que $\varepsilon \sim N(0, \sigma^2 I)$ el logaritmo natural de la función de probabilidad para el modelo SAR se encuentra dada por la ecuación número (1.27) toma la siguiente forma:

$$\ln L(\rho, \delta, \sigma^2) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 + \ln |A| - \frac{1}{2\sigma^2} (Ay - Z\delta)' (Ay - Z\delta) \quad (3)$$

En donde n es el número de observaciones, la expresión $I - \rho W$ es reemplazada por A . Los parámetros a partir de los cuales vamos a maximizar la probabilidad son ρ , δ y σ^2 . Luego se puede escribir los coeficientes regresivos δ y σ^2 en función de ρ como se presenta a continuación:

$$\delta = \delta_0 - \rho \delta_L \quad (4)$$

En donde δ_0 y δ_L corresponde a los coeficientes de la regresión por mínimo cuadrado ordinario (MCO) en una regresión de Z y Wy . De manera similar el error de la varianza dado por σ^2 puede ser estimado por:

$$\sigma^2 = (\phi_0 - \rho \phi_L)' (\phi_0 - \rho \phi_L) \frac{1}{n} \quad (5)$$

A continuación, se presentan los componentes

$$\phi_0 = y - Z\delta_0$$

$$\phi_L = Wy - Z\delta_L$$

Luego si $\delta_0 = (Z'Z)^{-1}Z'y$ y $\delta_L = (Z'Z)^{-1}Z'Wy$.

Si reemplazamos 1.33 y 1.32 en la función de probabilidad 1.31 nos da el valor el logaritmo de la función de la verosimilitud concentrada:

$$\ln L_{res}(\rho) = k + \ln |I - \rho W| - \frac{n}{2} \ln [(\phi_0 - \rho \phi_L)' (\phi_0 - \rho \phi_L)] \quad (6)$$

Donde k es una constante que no depende de ρ . Esto tiene la finalidad de simplificar el problema de uno multivariante a uno univariante. Para maximizar la función de log-verosimilitud planteada con respecto a ρ con estimador ρ^* , es igual al de máxima verosimilitud estimada ($\hat{\rho}_{ML} = \rho^*$). Se tiene conocimiento que la estimación de máxima verosimilitud posee un error en la estimación cuando se poseen muestras pequeñas. Este tipo de cálculo tiene un problema de optimización para modelos con un gran número de

observaciones ya que necesita calcular el log determinante de una matriz de $n \times n$ de $(I - \rho W)$. Esto se puede solucionar por 2 estrategias, la primera es resolver utilizando estimadores alternativos, por ejemplo, variables instrumentales (Anselin, 1988). La segunda alternativa es en atacar directamente las dificultades de cálculo que enfrenta la estimación de máxima verosimilitud utilizando el enfoque de matriz dispersa de Pace and Barry (1997).

La inferencia relativa a los parámetros de los modelos se basa frecuentemente en estimados de la matriz de varianzas y covarianzas. En los problemas en que el tamaño de muestra es pequeño, una matriz de varianzas asintótica basada en la matriz de información de Fisher para los parámetros $\eta = (\rho, \delta, \sigma^2)$ pueden utilizarse para proporcionar medidas de dispersión para estos parámetros. En el artículo de Anselin (Anselin, 1988) proporciona las expresiones analíticas necesarias para construir una matriz de información y realizar el cálculo.

Si utilizamos el método de cálculo de máxima verosimilitud en el modelo de error espacial de la ecuación 1.20 junto a los supuestos dados por las ecuaciones 1.22 y 1.23. Asumiendo normalidad en los términos de error y utilizando el jacobiano este modelo también, el logaritmo de la función de probabilidad es:

$$\ln L(\lambda, \beta, \sigma^2) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 + \ln |I - \lambda W| \quad (7)$$

$$- \frac{1}{2\sigma^2} (y - X\beta)' (I - \lambda W) (y - X\beta) \quad (8)$$

Si vemos el último valor de la ecuación 1.38, demuestra que condicionado a un determinado λ la función de máxima verosimilitud es equivalente al mínimo de la suma de los residuos al cuadrado, de una regresión donde la variable espacialmente dependiente es $y^* = y - \lambda W y$ en un conjunto de variables explicativas dada por $X^* = X - \lambda W X$.

Ahora si utilizamos la estimación realizada para los modelos de retardo espacial (SAR) y se estiman los parámetros β y σ^2 por máxima verosimilitud:

$$\hat{\beta}_{ml} = [X'(I - \lambda W)'(I - \lambda W)X]^{-1} X'(I - \lambda W)'(I - \lambda W) \quad (9)$$

$$\hat{\sigma}_{ml}^2 = (\phi - \lambda W \phi)'(\phi - \lambda W \phi) \frac{1}{n} \quad (10)$$

Donde $\phi = Y - X \hat{\beta}_{ml}$

7 Descripción de datos

Para realizar este proyecto de tesis, se usarán 2 fuentes de información las cuales son Información Open Street Map (OpenStreetMap contributors, (2015) y Índices de movilidad (Bravo & Ferres, 2020). A continuación, describimos en detalle los datasets utilizados.

7.1 Open Street map

Es un proyecto Open Source, creado y mantenido por una comunidad de colaboradores (profesionales de cartografía, ingenieros, profesionales de GIS, entre otros), que contiene mapas editables para cada una de las ciudades del mundo, de libre disposición para toda la sociedad. Además, esta plataforma provee las posiciones de establecimientos e instalaciones y etiquetas que permiten agrupar a los establecimientos según su funcionalidad. En OSM llevan como nombre “amenitty” como, por ejemplo: bancos, centros de educación, iglesias, farmacias.

A continuación, se detalla el listado completo de categorías de establecimientos provistas por OSM:

Educación: centro de educación, colegios, universidades y centro de formación técnica (en OSM corresponde a las categorías *college*, *kindergarten*, *school*, *university*, *summer camp*, entre otros).

Retail: tiendas de retail y malls (en OSM corresponde las categorías de *mall, retail, supermarket, department store*, entre otro).

Oficinas: lugares de trabajo, oficinas, locales comerciales (en OSM corresponde a la categoría *professional*)

Gobierno: oficinas de gobierno (en OSM corresponde a *building public*)

Transporte: terminales de buses, paradas de bus, estaciones de metro, estaciones de tren, entre otros (en OSM corresponde a *Transportation*).

Comida: restaurantes y locales de comida rápida, entre otros (en OSM corresponde a las categorías de *fast_food, food_court, restaurant*, entre otros.)

Alojamiento: lugares para alojamiento, hoteles, hostales y entre otros (en OSM corresponde a las categorías de *hotel, hostel, motel, guest house*, entre otros).

Almacenes: almacenes de barrio (en OSM corresponde a las categorías *bakery, butchet, convenience*, entre otros).

Entretenimiento: librerías, cine, planetarios y centros comunitarios entre otros (en OSM corresponde a la categoría *entertainment*).

Finanzas: bancos (en OSM corresponde a *bank*)

Salud: hospitales, centros médicos, clínicas y consultas médicas (en OSM corresponde a las categorías *clinic, hospital, dentist, doctors* entre otros).

Money: cajas de cambio (en OSM corresponde *bureau de change*).

Vida nocturna: establecimientos de la vida nocturna, pub, discoteque y cervecerías (en OSM corresponde a las categorías, *bar, pub, nightclub, casino, gambling*)

Recreación: lugares de recreación, como piscinas, campamentos, centros deportivos, parques y quinchos (en OSM corresponde a las categorías, *parking entrance, swimming pool, soccer*, entre otros)

Religión: capillas e iglesias (en OSM corresponde a las categorías *church, chapel, temple, place of worship*, entre otros)

Reciclaje: lugares de reciclaje (en OSM corresponde a *recycling*).

Algunas de las categorías declaradas anteriormente incluyen algunas sub-agrupaciones de establecimientos. Por ejemplo, la categoría salud contiene a su vez las categorías clínicas, postas, hospitales, centros médicos, consultas médicas, centro de salud familiar (CESFAM), consultorio general urbano (CGU), entre otros.

Una visualización de la distribución de establecimientos por categoría en la Región Metropolitana es presentada en la Figura 7 y Figura 8. La Figura 7 presenta los establecimientos para las categorías: *alojamiento, vida nocturna, entretenimiento, trabajos, locales de comida, y de gobierno* mientras que la Figura 8 presenta los establecimientos para las categorías: *religión, reciclaje y natural*.

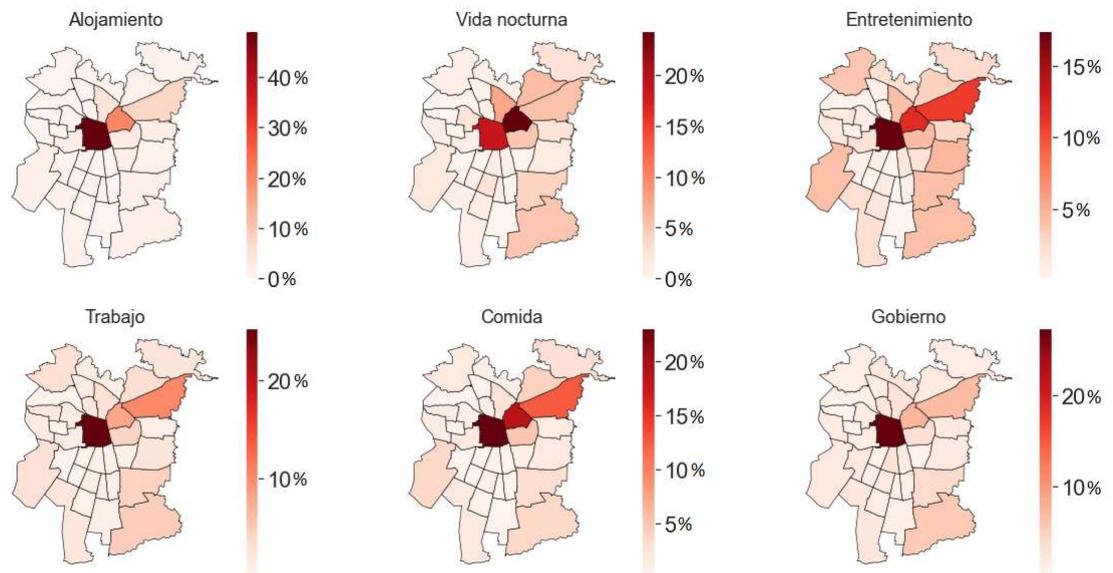


Figura 7: Porcentaje de establecimientos por comunas, según tipo. Elaboración propia

A partir de la figura 7 se puede apreciar que comunas como Santiago centro, Providencia, Las Condes y Ñuñoa poseen un porcentaje mayor de establecimiento con relación a las otras comunas de Santiago. El ejemplo más claro es la comuna de Santiago centro la cual contiene una gran proporción de alojamientos, vida nocturna, lugares de entretenimientos, lugares de trabajo, oficinas de gobierno.

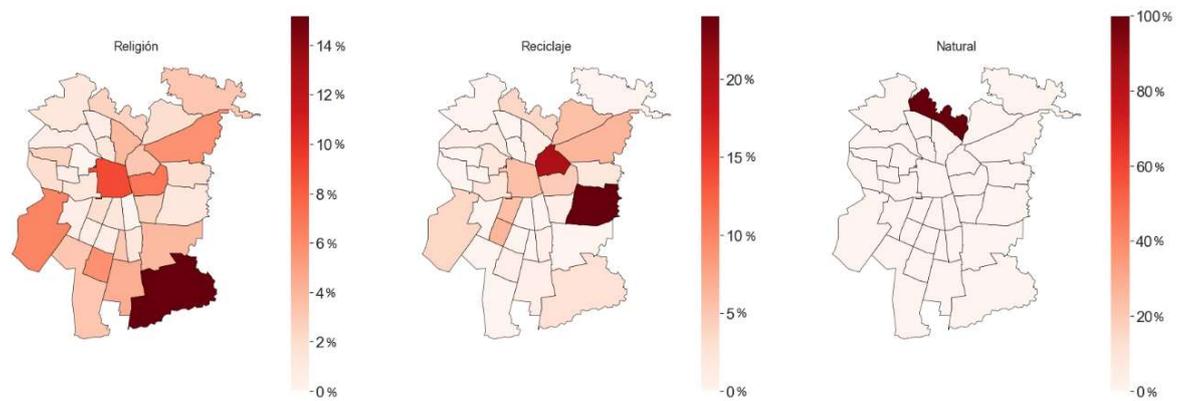


Figura 8: Porcentaje de establecimientos para la región metropolitana según tipo.

A partir de la figura 8 notamos que hay comunas en donde cierto tipo de establecimientos se presenta principalmente en una comuna. Por ejemplo, en Huechuraba se encuentra el número mayor de senderos y parques, en Peñalolén los centros de reciclaje y en Puente Alto un gran número de iglesias y capillas.

7.2 Índice de movilidad

Este índice es entregado por el instituto de Data Science de la Universidad de Desarrollo (Pappalardo et al, 2020) y se calcula a partir de registros detallados extendidos de teléfonos móviles (XDR) entregados por la compañía Telefónica Movistar, a partir de la siguiente expresión:

$$im = \frac{\text{Número de viajes}}{\text{Número de dispositivos}} \quad (11)$$

donde el número de viajes se obtiene a partir de la transición de un dispositivo de una antena telefónica a otra.

En particular se distinguen tres índices de movilidad, uno que considera los viajes externos de la comuna, uno que considera los viajes internos para una misma comuna y otro que considera los viajes de los residentes de una comuna, denominados im_{ext} , im_{int} y im_{res}

Para visualizar la evolución de la movilidad en el tiempo, se presentan dos figuras con la evolución de los índices de movilidad externo (figura 9) e interno (figura 10) para un subgrupo de comunas de la Región Metropolitana.

Las comunas elegidas en la visualización pueden ser agrupadas según el nivel socioeconómico como sigue: Lo Barnechea, Las Condes y Vitacura (*nivel socioeconómico alto*), Ñuñoa y Santiago (*nivel socioeconómico medio*) y Estación Central y La Cisterna (*nivel socioeconómico bajo*).

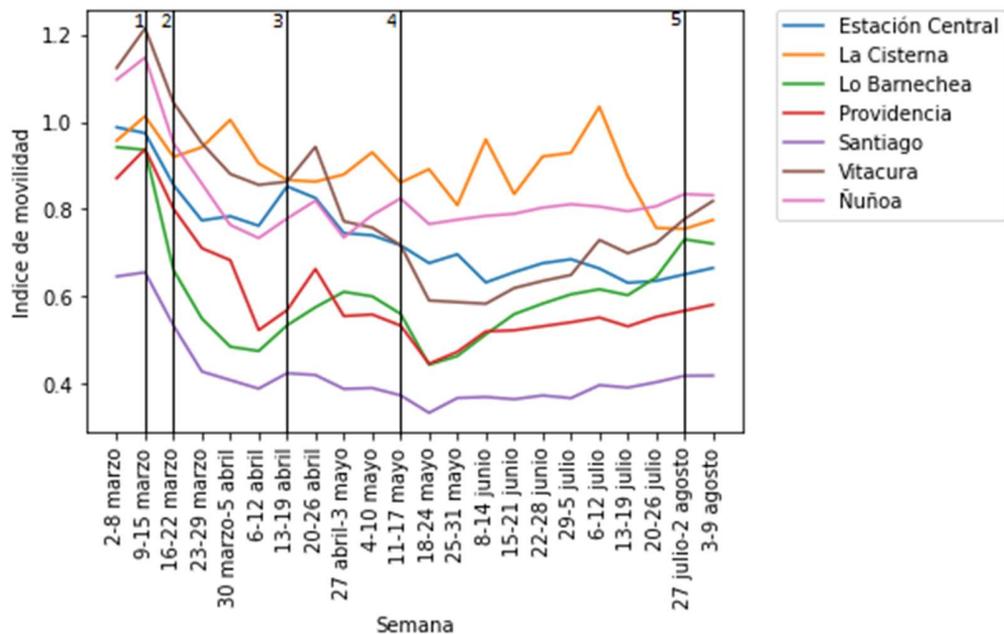


Figura 9: Evolución de la Movilidad Externa por Comuna. Evolución de movilidad externa de las comunas, Estación Central, lo Barnechea, Providencia, Santiago, Vitacura, Ñuñoa. Las líneas verticales de la figura identifican fechas destacadas del año 2020 en

donde, 1 corresponde al 11 de Marzo (OMS declara Pandemia), 2 corresponde al 14 marzo (Chile entra a fase 4), 3 corresponde a 19 de abril (la “nueva normalidad” en Chile), 4 corresponde al 13 de mayo (se decreta cuarentena para el 90% de la Región Metropolitana) y 5 corresponde al 28 de Julio (inicio transición)

A continuación, se presenta en la figura 10 presenta del índice de movilidad interno para el mismo subgrupo de comunas de la Región Metropolitana.

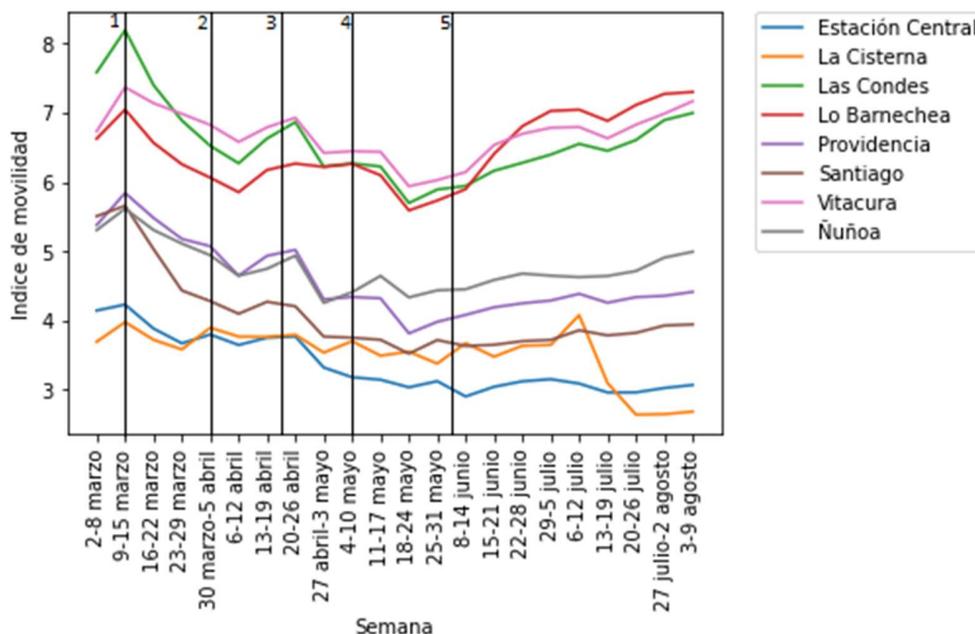


Figura 10: Evolución de la Movilidad Interna por Comuna. Evolución de movilidad dentro de las comunas Estación Central, lo Barnechea, Providencia, Santiago, Vitacura, Ñuñoa Las líneas verticales de la figura identifican fechas destacadas del año 2020 en donde, 1 corresponde al 11 de Marzo (OMS declara Pandemia), 2 corresponde al 14 marzo (Chile entra a fase 4), 3 corresponde a 19 de abril (la “nueva normalidad” en Chile), 4 corresponde al 13 de mayo (se decreta cuarentena para el 90% de la Región Metropolitana) y 5 corresponde al 28 de Julio (inicio transición).

8 Metodología

8.1 Selección de variables independientes

Primero, para seleccionar las variables a utilizar (*tipos de establecimientos*), realizamos un análisis de correlación para los distintos tipos establecimientos declarados en Open Street Map (OSM), cuyo resultado puede ser visualizado en las Figuras 11 y 12.

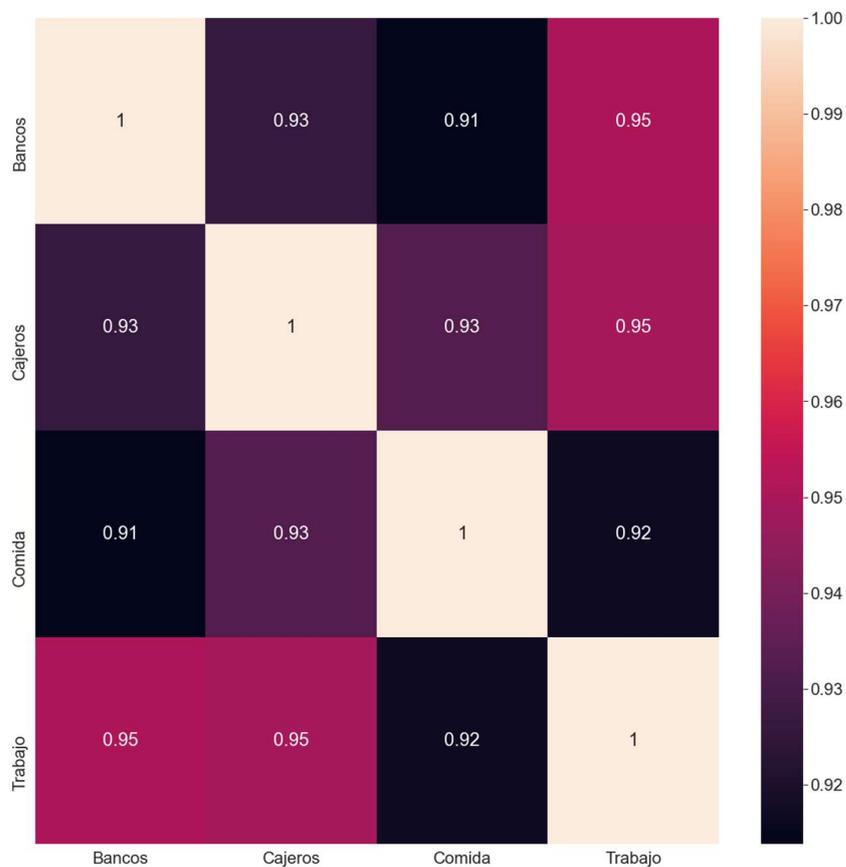


Figura 11: Matriz de correlación para los tipos de establecimiento para las categorías: bancos, cajeros automáticos, locales de comida y trabajo.

A partir de la Figura 11, notamos que, por un lado, existen algunos tipos de establecimientos cuya presencia está altamente correlacionada (correlación >0.9) con la presencia de otros. Ejemplos de esto son: la alta correlación existente entre los bancos y

los cajeros automáticos y la alta correlación entre los establecimientos de comida y trabajo.

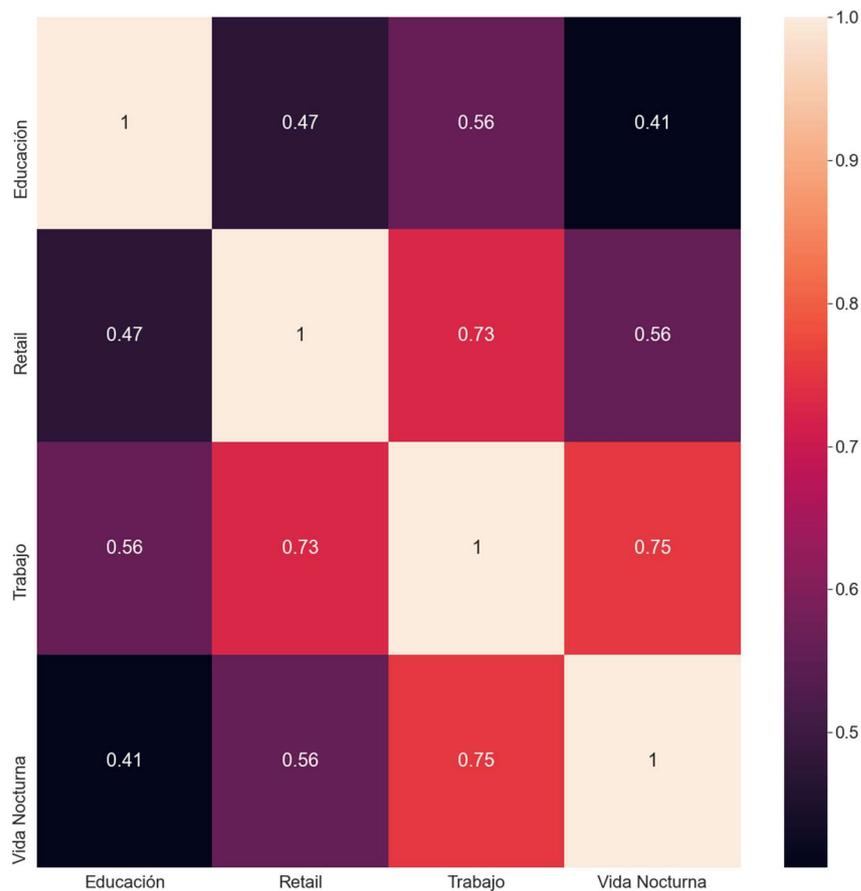


Figura 12 Matriz de correlación para los tipos de establecimiento para las categorías: educación, tiendas de retail, trabajo y establecimientos de vida nocturna.

Por otro lado, a partir de la Figura 12, notamos que existen tipos de establecimientos cuya presencia no está altamente correlacionadas (correlación < 0.8), como es el caso de los establecimientos educacionales con los de vida nocturna, o de los establecimientos educacionales con las tiendas de retail.

Una vez realizado el análisis de correlación para asegurarnos de que no exista colinealidad entre los predictores x_i , decidimos incorporar al modelo de regresión los establecimientos las siguientes categorías de: *educación, tiendas de retail, trabajo y vida nocturna*.

8.2 Asignación de pesos

A continuación, asignamos los pesos en el modelo GWR, para lo cual se utilizó el método de selección óptima de ancho de banda por medio del criterio de información de akaike corregido AICc (Akaike, 1974)., basado en la función gaussiana (revisar Sección 6.2.5.2).

8.3 Estimación de parámetros $\hat{\beta}_i$ locales

Finalmente, realizamos una estimación de los parámetros $\hat{\beta}_i$ locales y calculamos los coeficientes R^2 de cada modelo. Cabe mencionar que se realizara este procedimiento para cada una de las semanas para posteriormente comparar resultados entre periodos.

8.4 Fechas destacadas

Finalmente, con los resultados de los parámetros calculados, se realiza una comparación de algunos hitos en el manejo de la pandemia. Estos se declaran a continuación:

- Suspensión de clases, con fecha del día 15 de marzo.
- Cuarentenas parciales para las comunas Independencia, Las Condes, Lo Barnechea, Vitacura, Ñuñoa, Providencia y Santiago, con fecha 25 de marzo
- Cuarentena total de la Región Metropolitana, con fecha 15 de mayo.

9 Resultados

Esta sección se presentará los resultados de los R^2 y la variabilidad espacial de los coeficientes locales de las variables explicativas (elasticidades) del modelo GWR implementado, para el índice de movilidad externo y el interno.

A continuación, se presentan los modelos implementados:

Movilidad externa

$$im_{i\ ext} = \beta_{i0} + \beta_i x_i \text{ educación} + \beta_i x_i \text{ retail} + \beta_i x_i \text{ trabajo} + \beta_i x_i \text{ vida nocturna} + \varepsilon_i \quad (12)$$

En donde $i = 1, \dots, n$

Movilidad interna

$$im_{i\ res} = \beta_{i0} + \beta_i x_i \text{ educación} + \beta_i x_i \text{ retail} + \beta_i x_i \text{ trabajo} + \beta_i x_i \text{ vida nocturna} + \varepsilon_i \quad (13)$$

En donde $i = 1, \dots, n$

9.1 Resultados de R^2

A continuación, se presentan los resultados de los R^2 para el modelo GWR por comuna, según semana, tanto para índice de movilidad externo como interno.

9.1.1 Resultados de R^2 para índices de movilidad externos

La distribución espacial de los ajustes locales productos por el GWR (R^2 locales), permite conocer la variación espacial de la explicación del modelo. La distribución del R^2 local a nivel de comuna varía entre 0 y 1 (figura 13), teniendo el modelo una mejor capacidad explicativa para la zona sur de Santiago, incrementándose los R^2 por encima del 0.8. Por el contrario, en las comunas de mayor porcentaje de establecimiento presenta como el ajuste es inferior a 0.4.

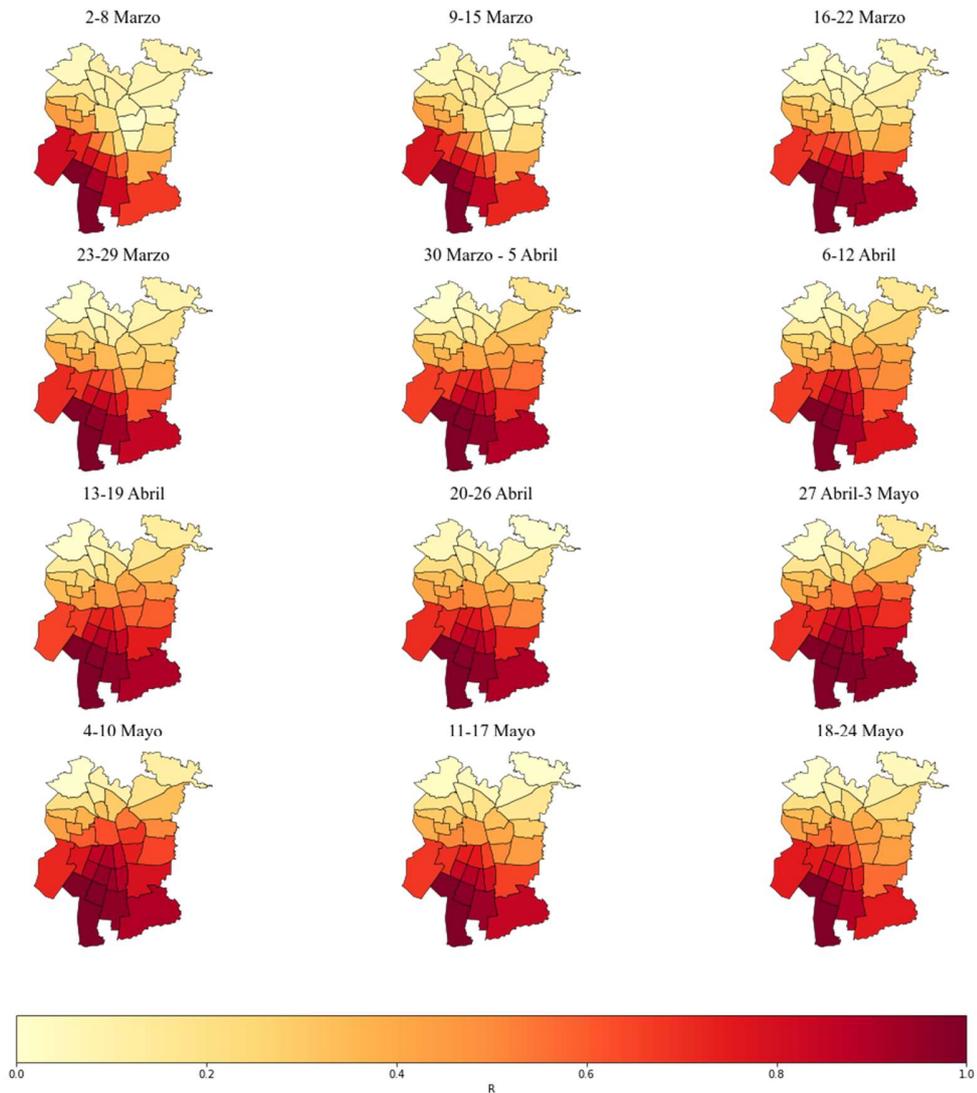


Figura 13: Distribución espacial de los R^2 locales para el modelo GWR con índice de movilidad externo, por semana.

9.1.2 Resultados de R^2 para índices de movilidad internos

Por el contrario para el modelo con índice de movilidad interno, el ajuste del R^2 se presenta en mayor medida en el sector centro norte de la región metropolitana, mientras que en las zonas más alejadas los R^2 son inferiores al 0,4 (ver figura 14).

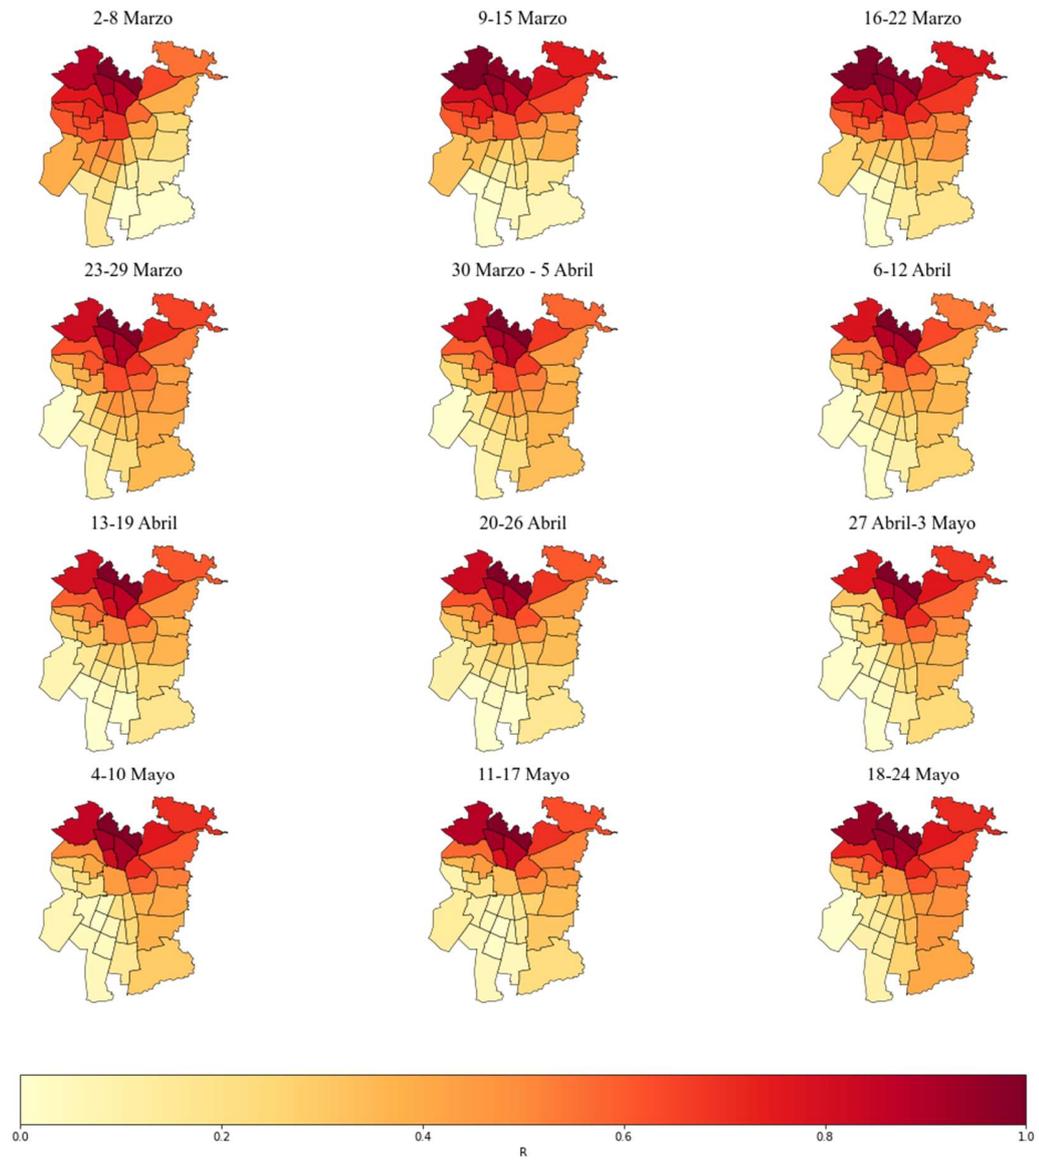


Figura 14: Distribución espacial de los R^2 locales para el modelo GWR con índice de movilidad interno, por semana.

9.2 Resultados de los coeficientes locales

Para el análisis de la variabilidad espacial de los coeficientes locales de las variables explicativas (elasticidades) del modelo GWR, tanto para el índice de movilidad externo y el interno, fueron consideradas algunas fechas relevantes del manejo de la pandemia en Chile con la finalidad de comparar lo sucedido entre periodos previo y posterior.

9.2.1 Resultados de los coeficientes locales para los índices de movilidad externos.

A continuación, presentamos los comparativos de las regresiones obtenidas considerando las fechas mencionados en la Sección 8.4.

La figura 15 contiene los coeficientes locales del modelo GWR para el índice de movilidad externo (ver ecuación 43) correspondiente a la semana del 9 y el 15 de marzo, semana en las que las clases fueron suspendidas, mientras que la figura 16 contiene los coeficientes locales para el mismo modelo, pero para la semana de 16-22 de marzo.

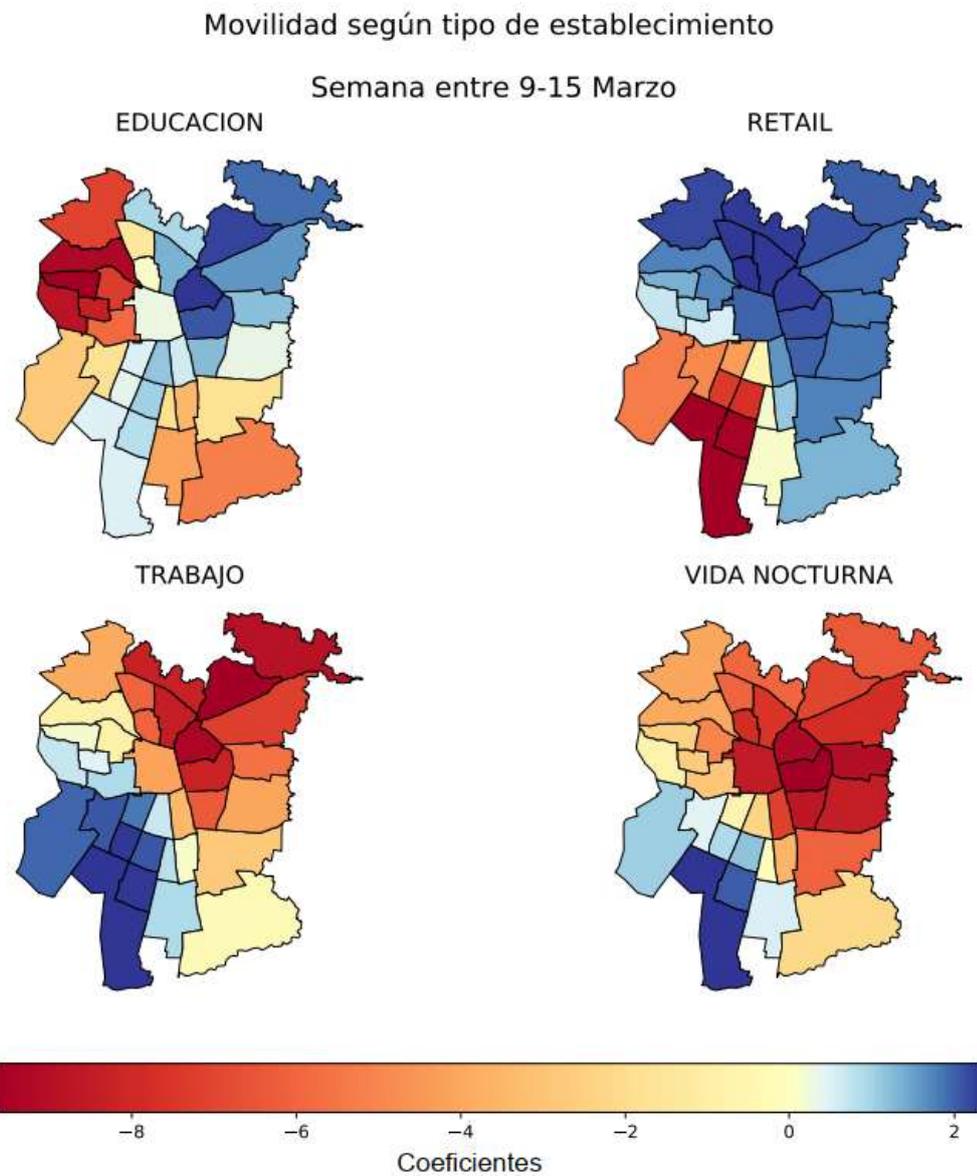


Figura 15: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad externo, por tipo establecimiento entre el 9 y el 15 de marzo.

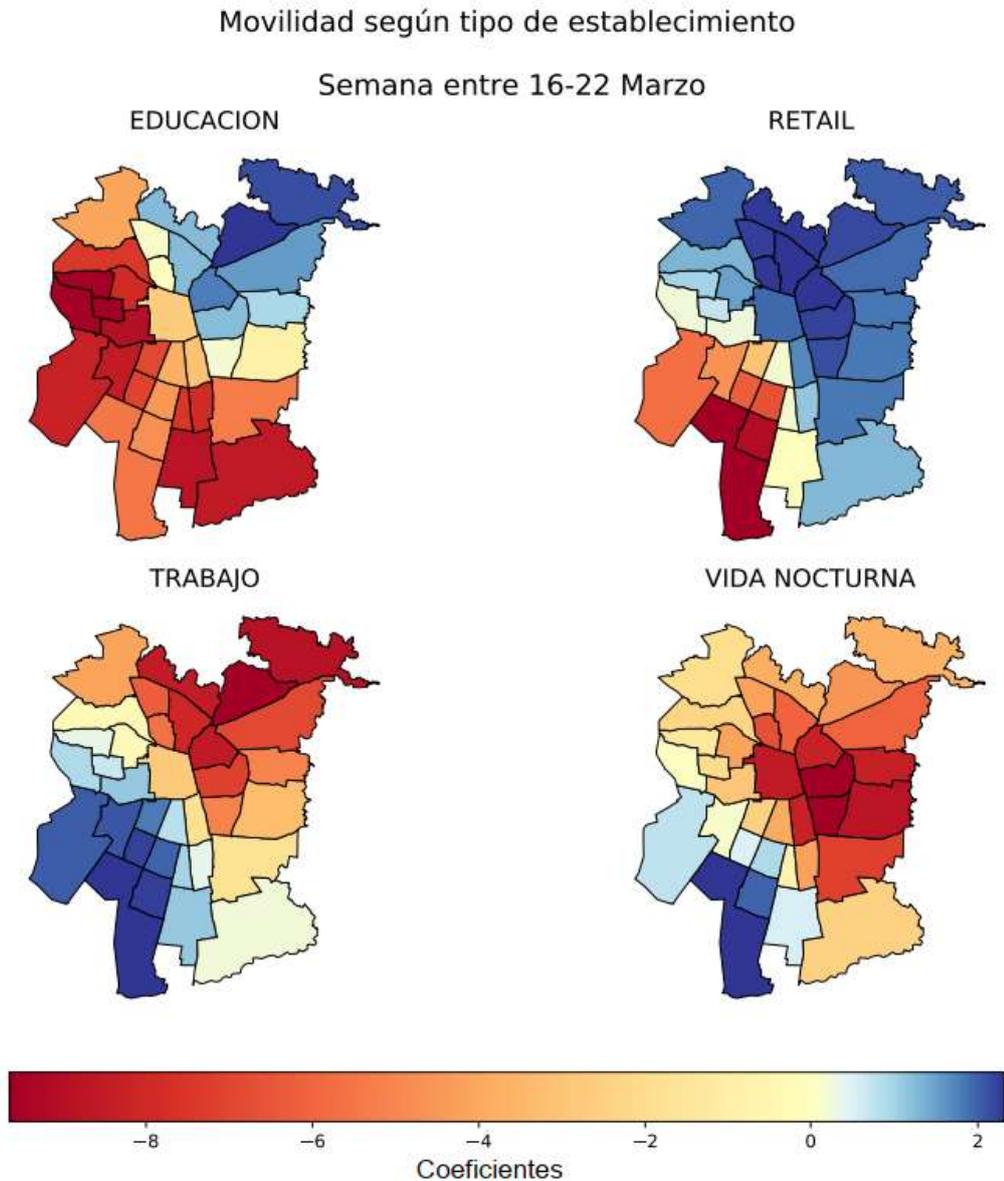


Figura 16: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad externo, por tipo establecimiento entre el 16 y el 22 de marzo.

Luego de la suspensión de clases, el cierre de los establecimientos de *educación* impacta en la movilidad externa principalmente en las comunas de San Bernardo, El Bosque, La Cisterna, Lo Espejo, Pedro Aguirre Cerda, San Miguel, San Joaquín, Maipú y Cerrillos.

La figura 17 contiene los coeficientes locales del modelo GWR para el índice de movilidad externo (ver ecuación 43) correspondiente a la semana del 16 y el 22 de Marzo, mientras que la figura 18 contiene los coeficientes locales para el mismo modelo, pero para las semana de 30 marzo y 5 de abril, semana siguiente luego que se decreta cuarentenas parciales dentro de la Región Metropolitana (25 de marzo) para las comunas de Independencia, Las Condes, Lo Barnechea, Vitacura, Ñuñoa, Providencia y Santiago (CNN, 2020).

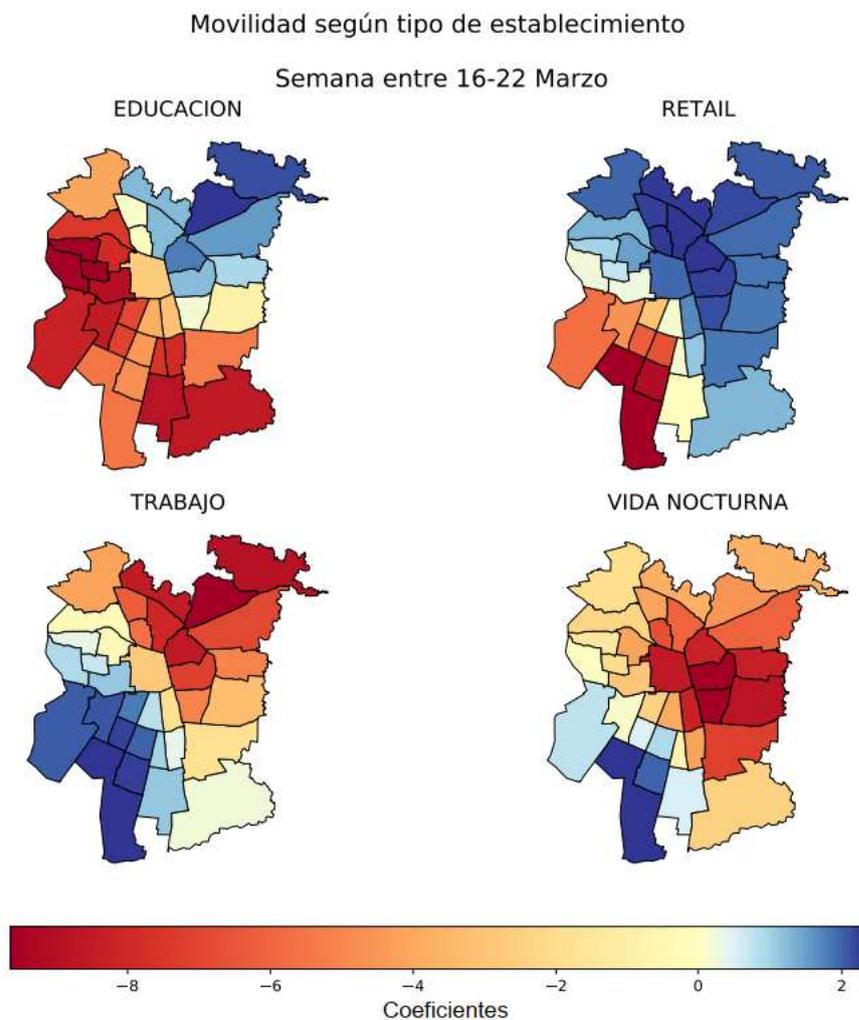


Figura 17: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad externo, por tipo establecimiento entre el 16 y el 22 de marzo.

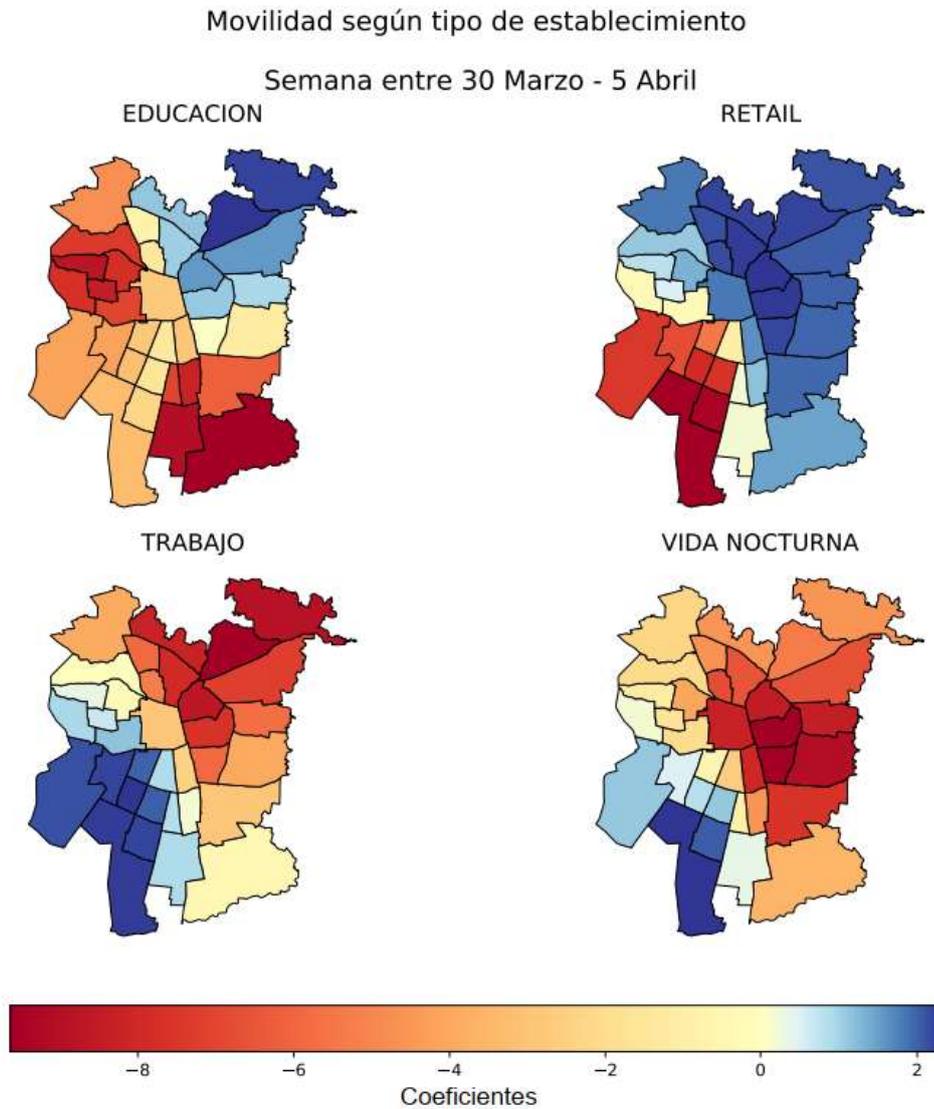


Figura 18: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad externo, por tipo establecimiento entre el 30 marzo y 5 de abril.

Después de comparar las figuras 17 y 18, notamos que no existe gran variación de los coeficientes locales para el modelo de movilidad externa. Esto podría explicarse por la alta diversidad y número de establecimientos presentes en las comunas en las que primero se aplicaron restricciones, los cuales le permiten a la población no realizar viajes a otras comunas, restricciones en contraste a las comunas periféricas de la Región.

La figura 19 contiene los coeficientes locales del modelo GWR para el índice de movilidad externo (ver ecuación 43) correspondiente a la semana 4 y el 10 de mayo, mientras que la figura 20 contiene los coeficientes locales para el mismo modelo pero para la semana de 18 y el 24 de mayo, semana siguiente luego de que se decreta cuarentena total (15 de mayo) para la Región Metropolitana (emol, 2020).

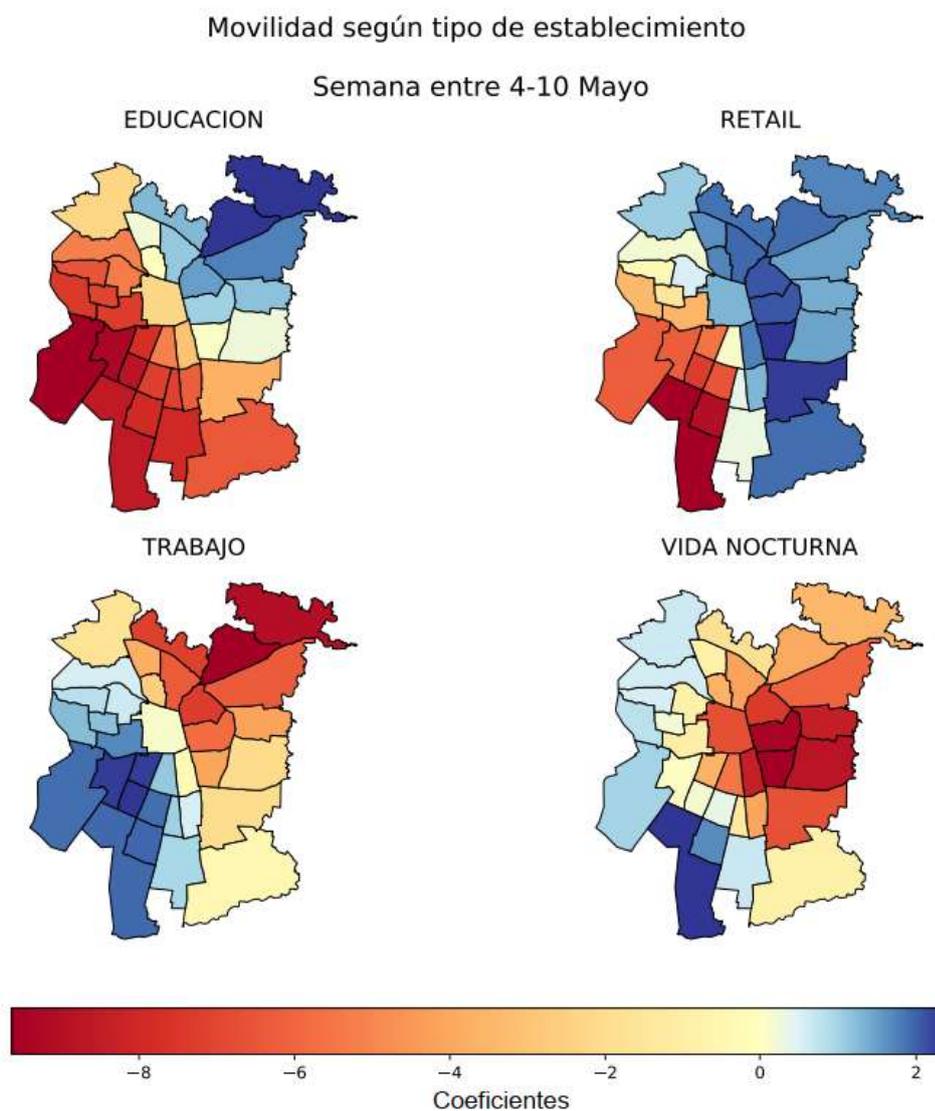


Figura 19: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad externo, por tipo establecimiento entre el 4 al 10 de mayo.

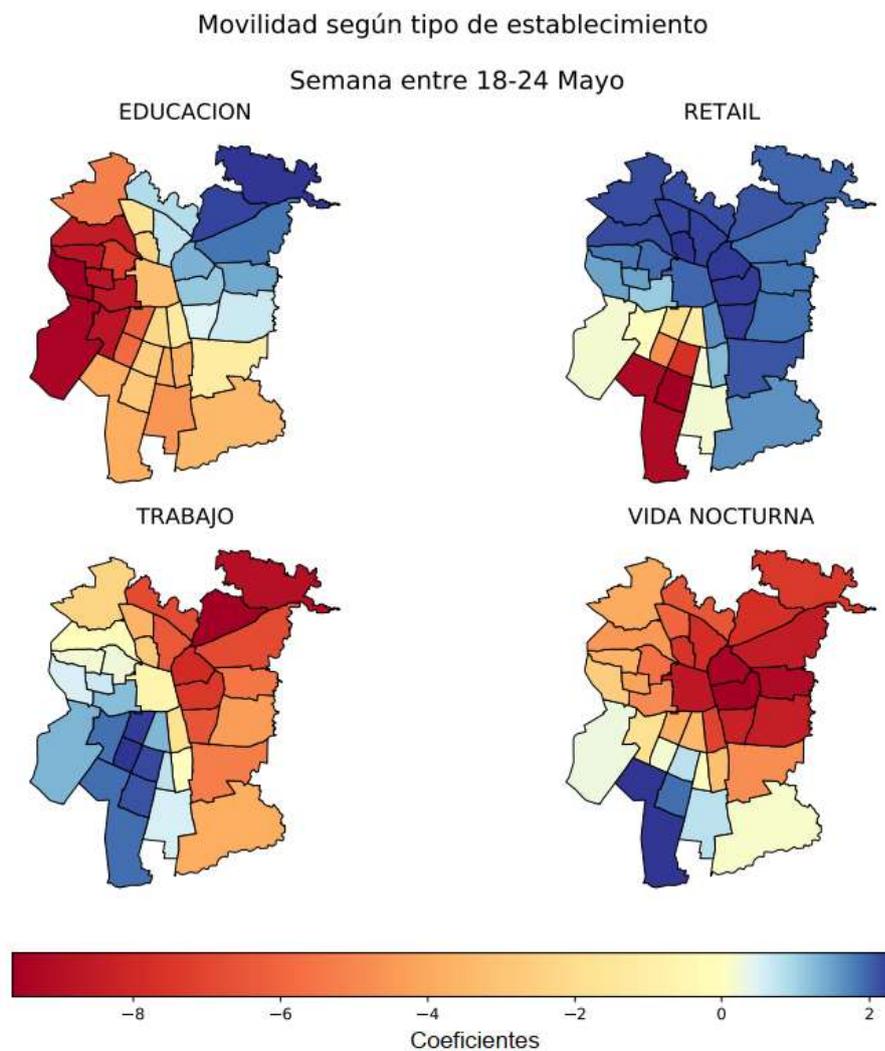


Figura 20: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad externo, por tipo establecimiento entre el 18 y el 24 de mayo.

Después de comparar las figuras 19 y 20 para el tipo de establecimiento *trabajo*, podemos ver que el coeficiente disminuye en las comunas del sector poniente: Maipú, Pudahuel, Cerrillos, Renca, Cerro Navia, Quinta Normal así como en las comunas del sector sur como La Pintana, Puente Alto, La Florida, Peñalolén, Macul. Esto podría explicarse por la alta concentración de establecimientos laborales en el centro de la ciudad, fuera de esas

comunas, que durante la cuarentena tuvieron acceso restringido. Por otro lado, para e los coeficientes asociados a establecimientos de *vida nocturna*, notamos que gran parte del sector poniente, presenta valores entorno entre 0,5 y 1. Comunas como Quilicura, Renca, Cerro Navia Pudahuel y Maipú muestran con coeficientes locales menores a 0.

9.2.2 Resultados de los coeficientes locales para los índices de movilidad interna.

A continuación, presentamos comparativos de las regresiones obtenidas considerando las fechas declaradas en la sección 8.4.

La figura 21 contiene los coeficientes locales del modelo GWR para el índice de movilidad interno (ver ecuación 44) correspondiente a la semana del 9 y el 15 de marzo, mientras que la figura 22 contiene los coeficientes locales para el mismo modelo, pero para la semana 16 y 22 de marzo.

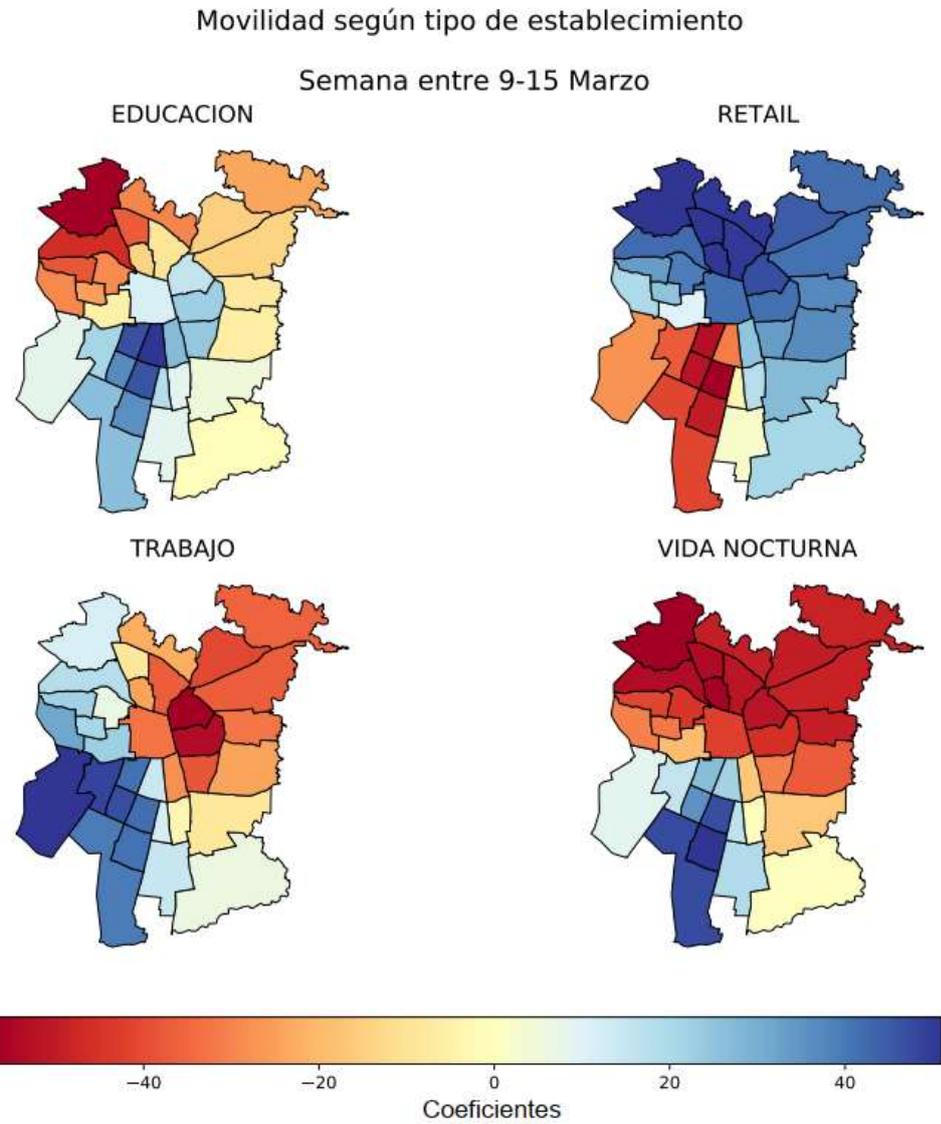


Figura 21: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad interno, por tipo establecimiento entre el 9 y el 15 de marzo.

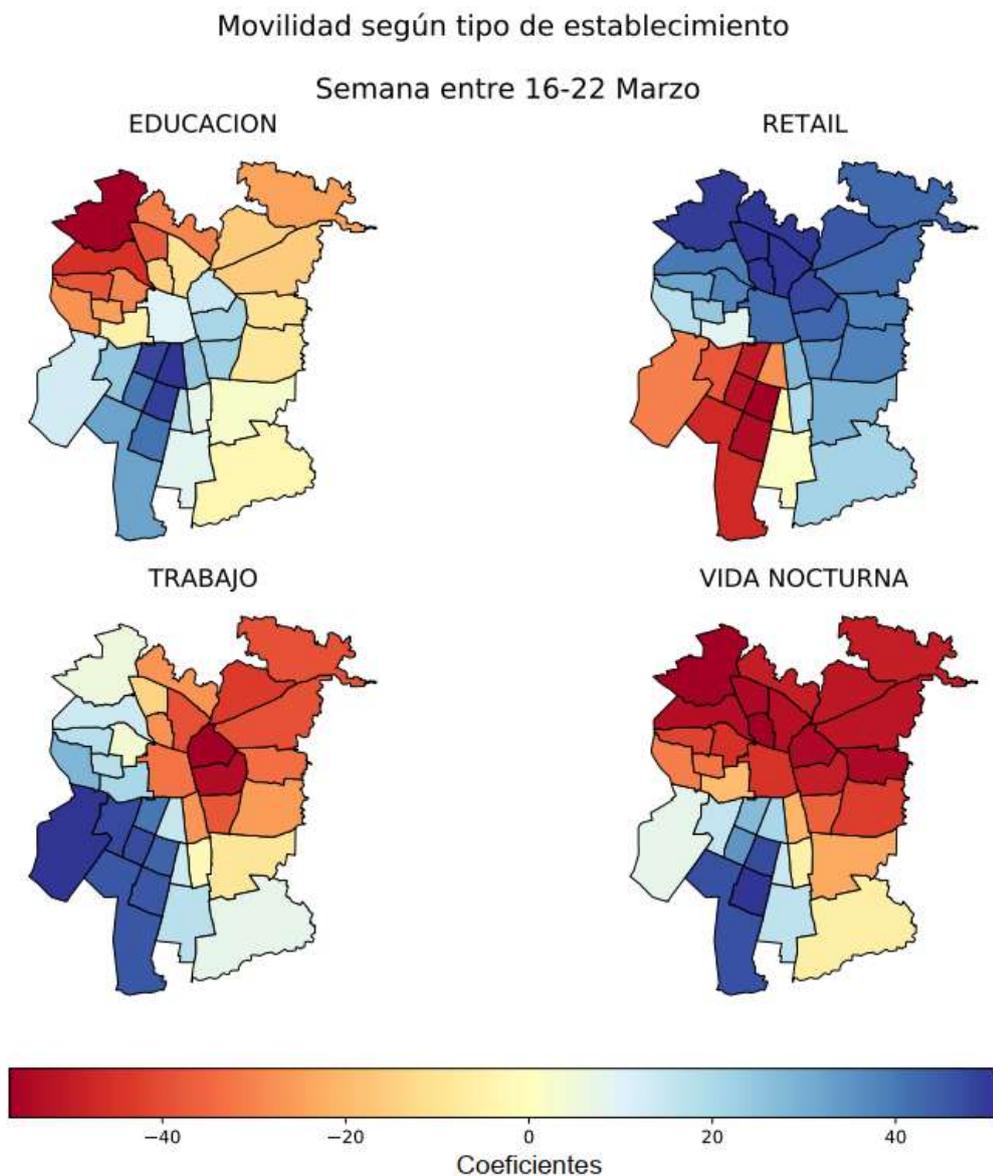


Figura 22: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad interno, por tipo establecimiento entre el 16 y el 22 de marzo.

Comparando las figuras 21 y 22, notamos que el cierre de los establecimientos educacionales, no afecta significativamente en la movilidad interna de las comunas de la Región Metropolitana.

La figura 23 contiene los coeficientes locales del modelo GWR para el índice de movilidad interno (ver ecuación 44) correspondiente a la semana del 16 y el 22 de Marzo, mientras que la figura 24 contiene los coeficientes locales para el mismo modelo, pero para la semana de 30 marzo y 5 de abril, semana siguiente luego que se decreta cuarentenas parciales dentro de la Región Metropolitana (25 de marzo) para las comunas de Independencia, Las Condes, Lo Barnechea, Vitacura, Ñuñoa, Providencia y Santiago (CNN, 2020).

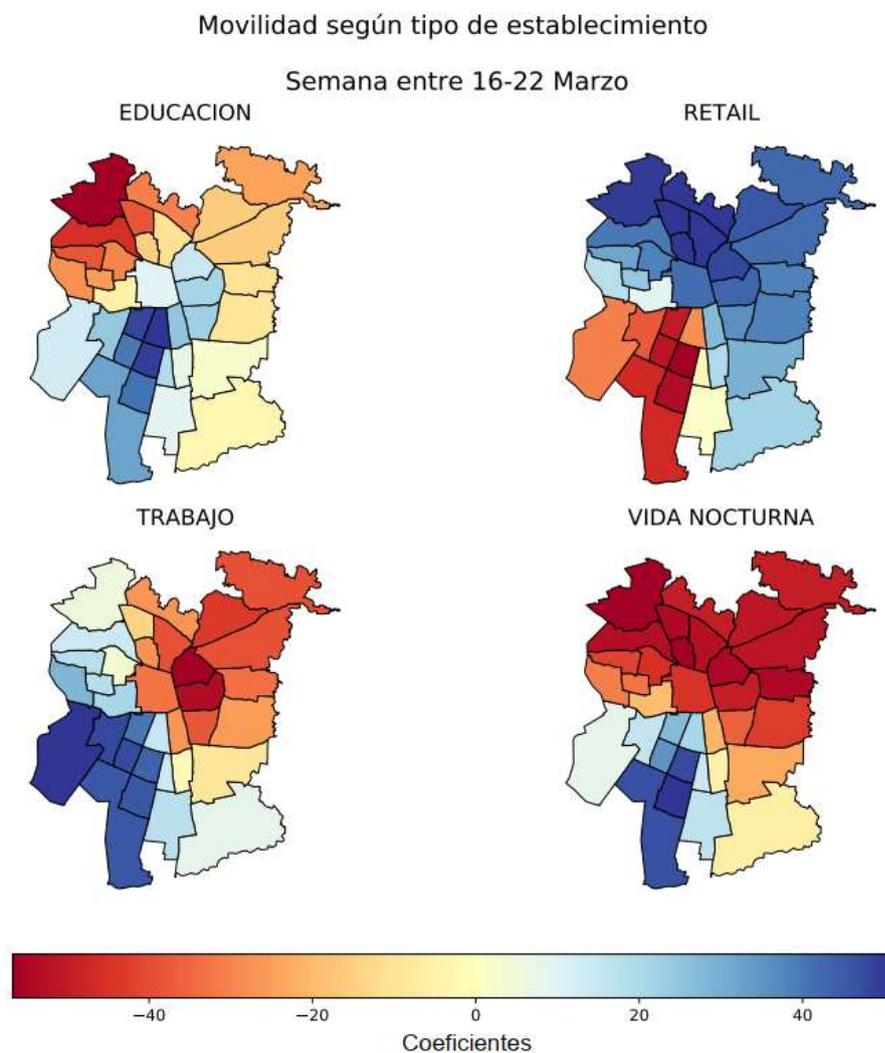


Figura 23: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad interno, por tipo establecimiento entre el 16 y el 22 de marzo.

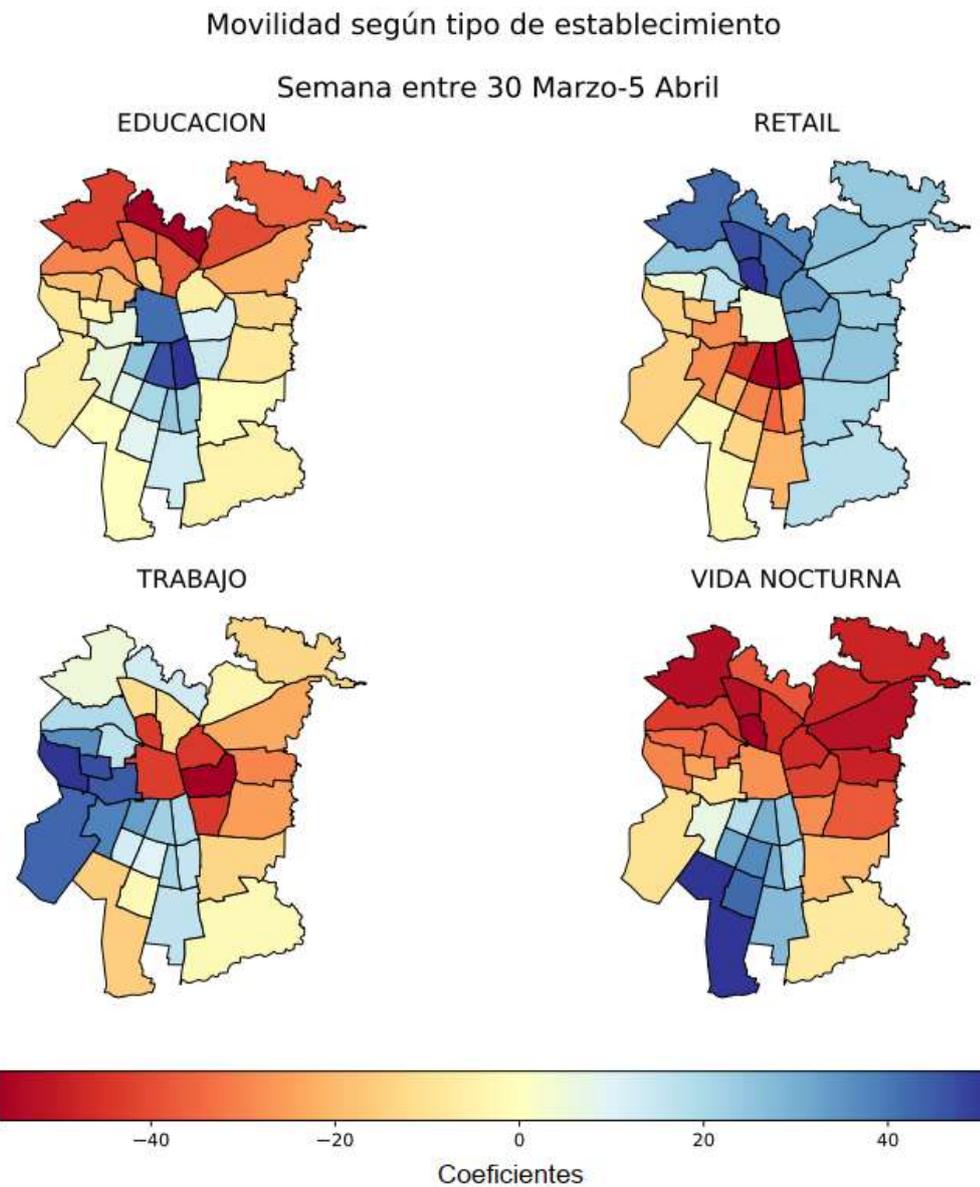


Figura 24: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad interno, por tipo establecimiento entre el 30 marzo y el 05 de abril.

Al comparar las figuras 23 y 24, notamos que existe una disminución en los coeficientes locales para el modelo GWR de movilidad interna. Notamos que los coeficientes para los establecimientos de tipo *retail*, disminuyen para una gran parte de las comunas del sector

norte oriente de la Región Metropolitana. En contraste, para las comunas del sector sur poniente: San Bernardo, El Bosque, La Cisterna, Lo Espejo y Pedro Aguirre Cerda, se observa un aumento de este coeficiente. Para los coeficientes asociados a establecimientos de *trabajo*, se observa una disminución en las comunas del sector sur poniente de la Región Metropolitana: Maipú, Cerrillo, San Bernardo, El Bosque y un aumento leve en las comunas del sector norte oriente: Lo Barnechea, Vitacura, Huechuraba, Las Condes, Providencia, La Reina, Peñalolén.

La figura 25 contiene los coeficientes locales del modelo GWR para el índice de movilidad interno (ver ecuación 44) correspondiente a la semana 4 y el 10 de mayo, mientras que la figura 26 contiene los coeficientes locales para el mismo modelo pero para la semana de 18 y el 24 de mayo, semana siguiente luego que se decreta cuarentena total (15 de mayo) para la Región Metropolitana (emol, 2020).

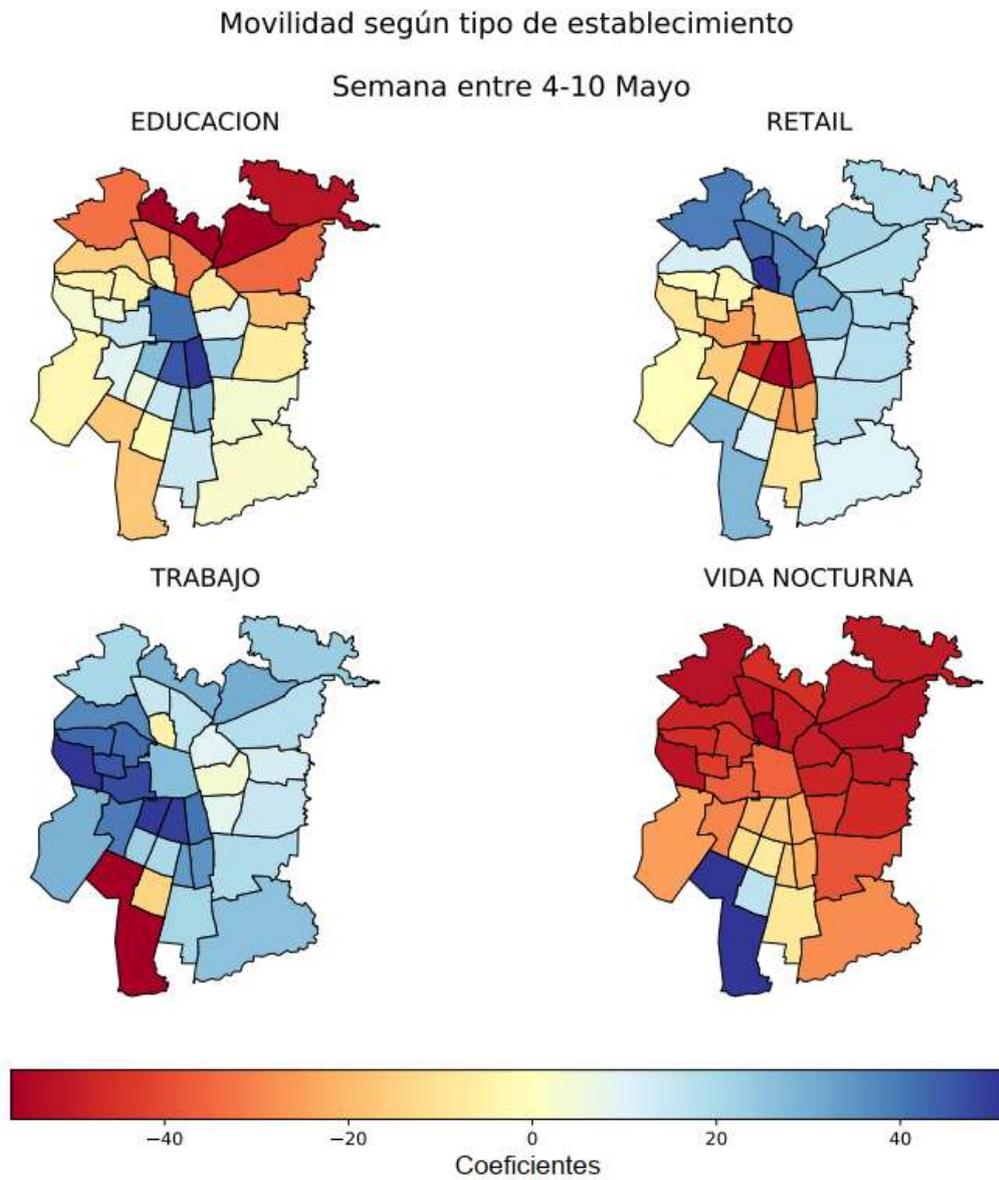


Figura 25: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad interno, por tipo establecimiento entre el 4 y el 10 de mayo.

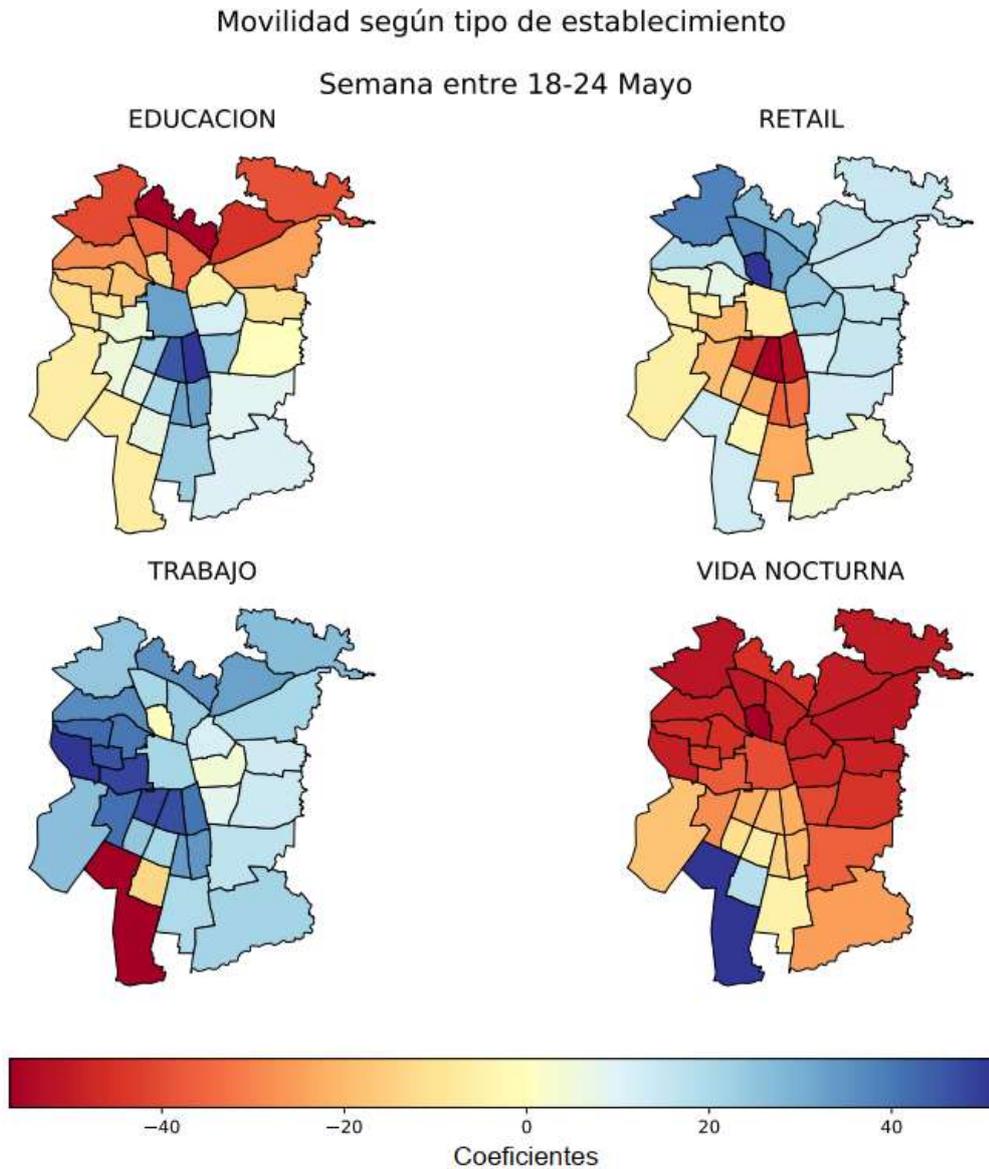


Figura 26: Distribución espacial de los coeficientes locales del modelo GWR para el índice de movilidad interno, por tipo establecimiento entre el 18 y el 24 de mayo.

Si comparamos las figuras 25 y 26, para el establecimiento *trabajo*, podemos ver la tendencia como el coeficiente disminuye (como Maipú, Pedro Aguirre Cerda, Maipú, La Florida), pero aumenta las comunas de la parte norte de Santiago Quilicura, Huechuraba,

Vitacura y Lo Barnechea. Con relación a la vida nocturna, gran parte de la Región Metropolitana mantuvieron coeficientes locales similares luego de la cuarentena total.

10 Conclusiones

A partir de los resultados presentados en este trabajo concluimos que es posible explicar las diferencias en movilidad en las comunas de la Región Metropolitana utilizando las distintas distribuciones de establecimientos durante las restricciones de movilidad. En específico, este trabajo revela que:

- Luego de la suspensión de clases, el cierre de los establecimientos de *educación* impacta en la movilidad externa principalmente en las comunas de San Bernardo, El Bosque, La Cisterna, Lo Espejo, Pedro Aguirre Cerda, San Miguel, San Joaquín, Maipú y Cerrillos.
- Luego de la cuarentena parcial, los distintos tipos de establecimiento no impactan en la movilidad externa de las comunas de Independencia, Las Condes, Lo Barnechea, Vitacura, Ñuñoa, Providencia y Santiago, esto podría ser explicado por la presencia de un alto número de establecimientos de todo tipo en estas comunas, lo que facilita la movilidad de la población en sus propias comunas.
- Luego de la cuarentena total, el impacto de los establecimientos de tipo *trabajo* en la movilidad externa disminuye las comunas del sector poniente: Maipú, Pudahuel, Cerrillos, Renca, Cerro Navia, Quinta Normal así como para las comunas del sector sur: La Pintana, Puente Alto, La Florida, Peñalolén, Macul, esto se podría explicar por la alta concentración de establecimientos laborales fuera de esas comunas.

11 Trabajo futuro

Como continuación de este trabajo de tesis y como cualquier otro proyecto de investigación, existen algunas áreas de trabajo en las cuales se puede continuar el proyecto. Como son fuentes de información, modelos utilizados, fechas de estudio entre otros.

A continuación, se presentan algunos trabajos futuros que pueden desarrollarse y por exceder el alcance de este proyecto no se pudieron tratar con mayor profundidad. Los trabajos futuros se pueden desarrollar son:

- Utilizar alguna otra fuente de información como Google Maps, el contiene información más completa.
- Realizar un análisis similar utilizando los datos de movilidad reportados por Google.
- Aplicar otros modelos similares al utilizado por ejemplo la regresión ponderada geográficamente multiescala (MGWR) o mínimos cuadrados ordinarios.
- Extender la serie de datos utilizadas e incorporar otras fechas claves y comparar el efecto previo y post a estas, por ejemplo, el retroceso a cuarentena del día 10 de diciembre.
- Utilizar como unidad de análisis el distrito censal en vez de la comuna, con la finalidad de tener información más desagregada.
- Cuantificar el efecto de la presencia, apertura y cierre de los distintos tipos de establecimiento en la movilidad.

12 Bibliografía

- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 716 - 723.
- Anselin, L. (1988). *Spatial Econometrics: Methods and Models*. Dordrecht: Springer.
- Bengtsson, L., Gaudart, J., Lu, X., Moore, S., Wetter, E., Sallah, K., . . . Piarroux, R. (2015). Using Mobile Phone Data to Predict the Spatial Spread of Cholera. *nature*.
- Bravo, L., & Ferres, L. (1 de 11 de 2020). *Instituto de Movilidad UDD*. Obtenido de http://datascience.udd.cl/reports/11-04_COVID_IM_Nacional.pdf
- Burrige, P. (1980). On the Cliff-Ord Test for Spatial Correlation. *Journal of the Royal Statistical Society*, 107-108.
- CNN, C. (05 de Mayo de 2020). *cnn chile*. Obtenido de https://www.cnnchile.com/coronavirus/hitos-claves-covid-19-chile-mundo-cronologia_20200505/
- Daniela, C. (2012). *Referencia a la movilidad urbana, problemas y estrategias en la ciudad de santiago*. Valparaiso: PUCV.
- emol. (13 de Mayo de 2020). *cooperativa.cl*. Obtenido de [emol.cl: https://www.emol.com/noticias/Nacional/2020/05/13/986037/razones-cuarenta-total-Santiago.html](https://www.emol.com/noticias/Nacional/2020/05/13/986037/razones-cuarenta-total-Santiago.html)
- Ferretti, L., Wymant, C., Kendall, M., Zhao, L., Nurtay, A., AbelerDörner, L., . . . Fraser, C. (2020). Quantifying SARS-CoV-2 transmission suggests epidemic control with digital contact tracing. *medrxiv*.
- Fischer, M., & Wang, J. (2011). *Spatial Data Analysis. Models, Methods and Techniques*. Springer.
- Fotheringham, A., Yang, W., & Kang, W. (2017). Multi-Scale Geographically Weighted Regression. *ISPRS International Journal of Geo-Information*, 1247-1265.

- Fritz, C., & Kauermann, G. (2008). On the Interplay of Regional Mobility, Social Connectedness, and the Spread of COVID-19 in Germany. *arxiv*.
- Getis, A., & Ord, K. (1992). The analysis of spatial association by distance statistics. *Geographical Analysis*, 189-206.
- Goodchild, M. F. (1987). *Spatial Autocorrelation. Concepts and Techniques in Modern Geography*.
- Gozzi, N., Tizzoni, M., Chinazzi, M., Ferres, L., Vespignani, A., & Perra, N. (2020). Estimating the effect of social inequalities in the mitigation of. *medrxiv*.
- Gutierrez J., G. J. (2012). Regresión Geográficamente Ponderada. *XV Congreso Nacional de Tecnologías de la Información Geográfica*, 19-21.
- Gutiérrez, A. (2010). *La movilidad de la metropolis desigual: El viaje a la salud publica y gratuita en la periferia de buenos aires*. Buenos Aires: Institutos y Centros de Investigación UBA -CONICET.
- Hadjidemetriou Georgios, S. M. (2020). The impact of government measures and human mobility trend on COVID-19 related deaths in the UK. *Transportation Research Interdisciplinary Perspectives*.
- Kraemer, M. (2020). The effect of human mobility and control measures on the COVID-19 epidemic in China. *Science*, 493-497. Obtenido de <https://doi.org/10.1126/science.abb4218>
- Martinez, m., & Rojas, C. (2015). Regresión geográficamente ponderada para la modelación de la accesibilidad a la red hospitalaria en el área metropolitana de concepción. *Revista Geográfica de Valparaíso*, 28-39.
- MINSAL. (27 de 11 de 2020). *Gobierno de Chile coronavirus*. Obtenido de <https://www.gob.cl/coronavirus/cifrasoficiales/>
- MINSAL. (02 de 09 de 2020). <https://www.gob.cl>. Obtenido de <https://www.gob.cl/coronavirus/pasoapaso/>
- MINSAL. (11 de 2020). *Sistema de Notificación EPIVIGILA. Depto. de Epidemiología, DIPLAS*. Obtenido de <https://www.gob.cl/coronavirus/cifrasoficiales/>
- Oliver, N. (2020). Mobile phone data and COVID-19: Missing an opportunity? *arXiv*.

- OMS[1]. (2019). *www.who.int*. Obtenido de <https://www.who.int/es/emergencias/diseases/novel-coronavirus-2019>
- OMS[2]. (2019). *Organizacion mundial de la salud*. Obtenido de Organización mundial de la salud (2019) Preguntas y respuestas sobre la enfermedad por coronavirus (COVID-19): <https://www.who.int/es/emergencias/diseases/novel-coronavirus-2019/advice-for-public/q-a-coronaviruses>
- OpenStreetMap contributors. ((2015)). *Open Street Map*. Obtenido de Planet dump retrieved from <https://planet.osm.org>: <https://www.openstreetmap.org>
- Oshan, T., li, Z., Kang, W., & Wolf, L. a. (2019). MGWR: A Python Implementation of Multiscale Geographically Weighted Regression for Investigating Process Spatial Heterogeneity and Scale. *ISPRS International Journal of Geo-Information*.
- Pappalardo, L., Cornacchia, G., Navarro, V., Bravo, L., & Ferres, L. (2020). A dataset to assess mobility changes in Chile. *physics.soc-ph*.
- Sepkowitz, K. A. (2001). AIDS — The First 20 Years. *New England Journal of Medicine*. *New England Journal of Medicine*, 1764-1772.
- Tsai, A., Harling, G., Zahra, R., & Rebecca, G. (2020). COVID-19 transmission in the U.S. before vs. after relaxation of state social distancing measures. *medrxiv*.
- Upton, G., & Fingleton, B. (1985). *Spatial data analysis by example. Vol.1: Point pattern and quantitative data*. Chichester: Wiley.
- W.H.O. (17 de 11 de 2020). *WHO Coronavirus Disease (COVID-19) Dashboard*. Obtenido de <https://covid19.who.int/>
- Waldo, T. (1970). A Computer Movie Simulating Urban Growth in the Detroit Region. *Economic Geography*, 234-240.
- Weill, J., Stigler, M., Deschenes, O., & Springborn, M. (2020). Social distancing responses to COVID-19 emergency declarations strongly differentiated by income. *Proceedings of the National Academy of Sciences*, 19658-19660.